

RAFAEL CAIUTA

**UTILIZANDO META-APRENDIZADO PARA SELEÇÃO DE
MODELOS DE CONFIABILIDADE DE SOFTWARE**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre. Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná.

Orientadora: Profa. Dra. Silvia Regina Vergilio.

Co-Orientadora: Profa. Dra. Aurora Trinidad Ramirez Pozo

CURITIBA

2007

RAFAEL CAIUTA

**UTILIZANDO META-APRENDIZADO PARA SELEÇÃO DE
MODELOS DE CONFIABILIDADE DE SOFTWARE**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre. Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná.

Orientadora: Profa. Dra. Silvia Regina Vergilio.

Co-Orientadora: Profa. Dra. Aurora Trinidad Ramirez Pozo

CURITIBA

2007

AGRADECIMENTOS

Esta é a seção mais fácil de escrever deste trabalho. É neste momento que deixo registrado todo o meu agradecimento às pessoas que colaboraram direta ou indiretamente com a concretização deste trabalho. Durante os dois anos de estudos, pesquisas, tentativas, erros e acertos diversas pessoas emprestaram com muita dedicação o seu tempo e atenção compartilhando conhecimento, técnicas e métodos para que o resultado do trabalho fosse o melhor possível. Evidentemente, o meu agradecimento especial é dirigido aos professores do Departamento de Informática da Universidade Federal do Paraná, Silvia Regina Vergilio, Aurora Pozo Trindade e Leonardo Emmendorfer que estiveram envolvidos diretamente na orientação, condução, revisão deste trabalho. Meu sincero muito obrigado a todos vocês!

SUMÁRIO

LISTA DE FIGURAS	vi
LISTA DE TABELAS	viii
RESUMO	ix
ABSTRACT	x
1 INTRODUÇÃO	1
1.1 Objetivos do Trabalho	3
1.2 Organização do Trabalho	4
2 APRENDIZADO DE MÁQUINA	5
2.1 Introdução ao Aprendizado de Máquina	5
2.1.1 Paradigmas de Aprendizado de Máquina	7
2.1.2 Hierarquia do Aprendizado Indutivo	8
2.1.3 Técnicas de Aprendizado de Máquina	10
2.1.3.1 Árvores de Decisão	10
2.1.3.2 Programação Genética	11
2.1.3.3 Redes Neurais	12
2.2 Meta-Aprendizado	14
2.3 Weka	15
2.4 Aprendizado de Máquina em Engenharia de Software	16
2.5 Considerações Finais	17
3 CONFIABILIDADE DE SOFTWARE	20
3.1 Definição	20
3.2 Modelos de Confiabilidade	22
3.2.1 Modelagem	22

3.2.2	Modelo de Jelinski-Moranda (JAM)	25
3.2.3	Modelo Geométrico (GEO)	26
3.2.4	Outros Modelos	27
3.2.5	Modelos de Confiabilidade Baseados em Aprendizado de Máquina .	28
3.3	Alguns Trabalhos de Seleção de Modelos de Confiabilidade	31
3.3.1	Seleção de Modelos Baseados na SDLC	33
3.3.2	Seleção de Modelo baseado em <i>Aikake Information Criterion</i>	35
3.4	Considerações Finais	36
4	META-APRENDIZADO APLICADO À CONFIABILIDADE DE SOFTWARE	38
4.1	Visão Geral	38
4.2	Descrição dos Dados	39
4.3	Experimentos	42
4.3.1	Passos dos Experimentos	44
4.3.1.1	Gerando a Tabela de Dados	44
4.3.1.2	Gerando Registros Sintéticos	44
4.3.1.3	Indicando o Melhor Modelo	49
4.3.1.4	Preparação das Tabelas de Resultados para Análise	53
4.4	Análise dos Resultados	56
4.4.1	Análise dos Resultados das Árvores de Decisão	60
4.4.1.1	Avaliação dos Resultados	62
4.4.2	Análise dos Resultados das Redes Neurais	65
4.4.2.1	Avaliação dos Resultados	66
4.4.3	Comparação Entre o Resultado de Árvores de Decisão e Redes Neurais	67
4.5	Considerações Finais	68
5	CONCLUSÃO	69
5.1	Trabalhos Futuros	70
	BIBLIOGRAFIA	82

A EXPERIMENTO JAM X GEO	83
B EXPERIMENTO JAM X RN	87
C EXPERIMENTO JAM X GEO X RN	91
D EXPERIMENTO JAM X GEO X PG2	95
E EXPERIMENTO JAM X RN X PG2	99
F EXPERIMENTO JAM X GEO X RN X PG2	103
G EXPERIMENTO JAM X PG2	107
H EXPERIMENTO PG1 X PG2	111
I EXPERIMENTO GEO X RN	115
J EXPERIMENTO GEO X PG2	119
K EXPERIMENTO GEO X RN X PG2	123
L EXPERIMENTO RN X PG2	127

LISTA DE FIGURAS

2.1	Hierarquia do Aprendizado Indutivo adaptada de [84]	9
2.2	Árvore de Decisão do C4.5	11
2.3	Uma Estrutura de Rede Neural	13
2.4	Uma Estrutura de Rede Neural MultiCamadas	14
2.5	Um Neurônio de uma Rede Neural	14
3.1	Distribuição dos Modelos de Acordo com a Fase de Desenvolvimento	34
4.1	Visão Geral do Trabalho	39
4.2	Caso 1 - Geração de dois registros sintéticos	47
4.3	Caso 2 - Geração de um registro sintético	47
4.4	Árvore de Decisão (JAM x GEO x PG2 x RN)	50
4.5	Árvore de Decisão (JAM x PG2 x RN)	50
4.6	Árvore de Decisão (JAM x GEO)	51
4.7	Experimentos JAM x GEO e JAM x RN	57
4.8	Experimentos JAM x GEO x RN e JAM x GEO x PG2	57
4.9	Experimentos JAM x RN x PG2 e JAM x GEO x RN x PG2	57
4.10	Experimentos JAM x PG2 e PG1 x PG2	58
4.11	Experimentos GEO x RN e GEO x PG2	58
4.12	Experimentos GEO x RN x PG2 e RN x PG2	58
4.13	Comparativo do Erro Médio Ótimo x Erro Médio dos Modelos	60
4.14	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	62
A.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	86
A.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	86
B.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	90
B.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	90

C.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	94
C.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	94
D.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	98
D.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	98
E.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	102
E.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	102
F.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	106
F.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	106
G.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	110
G.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	110
H.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	114
H.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	114
I.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	118
I.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	118
J.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	122
J.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	122
K.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	126
K.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	126
L.1	% de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão .	130
L.2	% de Melhora na Utilização de Meta-Aprendizado com Rede Neural	130

LISTA DE TABELAS

2.1	Aplicações de Aprendizado de Máquina na Engenharia de Software	18
2.2	Tipos de Métodos de Aprendizado de Máquina	19
3.1	Modelo de Jelinski–Moranda	30
3.2	Modelo Geométrico	31
3.3	Modelo baseado em RN	31
3.4	Modelo baseado em PG (Conjunto de Funções 1)	32
3.5	Modelo baseado em PG (Conjunto de Funções 2)	32
4.1	Tabela de Meta-Dados	43
4.2	Tabela JAM x GEO	44
4.3	Tabela JAM x GEO SINTÉTICOS	48
4.4	Tabela JAM x GEO - Modelos Indicados pelas Árvores e Redes Neurais . . .	52
4.5	Tabela Soma Erro Médio (Padronizado)	56
4.6	Comparativo Erro Médio Ótimo x Erro Médio Modelos (% de casos onde o método escolhido é igual ao Mét. Ótimo)	59
4.7	Tabela de Test t - Erro Médio da Árvore x Dados Não-Normalizados	61
4.8	Tabela de Test t - Erro Médio da Árvore x Dados Normalizados	61
4.9	Comparativo Erro Médio Árvore x Erro Médio Modelos (% Melhora)	61
4.10	Tabela de Teste t - Erro Médio Rede Neural x Dados Não-Normalizados . . .	65
4.11	Tabela de Teste t - Erro Médio Rede Neural x Dados Normalizados	65
4.12	Comparativo Erro Médio Rede Neural x Erro Médio Modelos (% Melhora) . .	65
A.1	Experimento JAM x GEO	84
A.2	Experimento JAM x GEO - Modelo Aleatório e Dados Normalizados	85
B.1	Experimento JAM x RN	88
B.2	Experimento JAM x RN - Modelo Aleatório e Dados Normalizados	89

C.1	Experimento JAM x GEO x RN	92
C.2	Experimento JAM x GEO x RN - Modelo Aleatório e Dados Normalizados	93
D.1	Experimento JAM x GEO x PG2	96
D.2	Experimento JAM x GEO x PG2 - Modelo Aleatório e Dados Normalizados	97
E.1	Experimento JAM x RN x PG2	100
E.2	Experimento JAM x RN x PG2 - Modelo Aleatório e Dados Normalizados	101
F.1	Experimento JAM x GEO x RN x PG2	104
F.2	Experimento JAM x GEO x RN x PG2 - Modelo Aleatório e Dados Normalizados	105
G.1	Experimento JAM x PG2	108
G.2	Experimento JAM x PG2 - Modelo Aleatório e Dados Normalizados	109
H.1	Experimento PG1 x PG2	112
H.2	Experimento PG1 x PG2 - Modelo Aleatório e Dados Normalizados	113
I.1	Experimento GEO x RN	116
I.2	Experimento GEO x RN - Modelo Aleatório e Dados Normalizados	117
J.1	Experimento GEO x PG2	120
J.2	Experimento GEO x PG2 - Modelo Aleatório e Dados Normalizados	121
K.1	Experimento GEO x RN x PG2	124
K.2	Experimento GEO x RN x PG2 - Modelo Aleatório e Dados Normalizados	125
L.1	Experimento RN x PG2	128
L.2	Experimento RN x PG2 - Modelo Aleatório e Dados Normalizados	129

RESUMO

A área de confiabilidade de software é considerada uma das mais críticas em Engenharia de Software. Diante disso, escolher qual o melhor modelo de confiabilidade a ser utilizado é uma tarefa importante, uma vez que os modelos apresentam resultados distintos para um mesmo conjunto de dados. Uma forma de selecionar qual o melhor modelo é analisar experiências e resultados de outras bases. Mas isto pode consumir muito tempo e esforço e nem sempre é uma tarefa trivial para a maioria dos gerentes de software. Para auxiliar na atividade de seleção de qual o modelo de confiabilidade a ser utilizado, este trabalho apresenta uma abordagem baseada em Meta-Aprendizado, uma sub-área do Aprendizado de Máquina. A tarefa de seleção é vista como uma tarefa de classificação, na qual as classes são os diferentes modelos. Para validação da abordagem foram realizados vários experimentos de comparação e seleção de qual o melhor modelo entre tradicionais ou paramétricos, e modelos não paramétricos que utilizam Redes Neurais e Programação Genética. Essa validação explora algumas características, meta-dados, de bases contendo dados de tempo entre falhas, tais como: variância, inclinação, auto-correlação e ruído médio. Dois classificadores foram avaliados, um baseado em árvores de decisão e outro em Redes Neurais. Ao final, um modelo é selecionado baseado no Erro Médio. Os resultados obtidos sugerem que a aplicação do Meta-Aprendizado é uma ferramenta importante para seleção do melhor modelo de confiabilidade.

ABSTRACT

Software reliability is considered one of the most critical tasks in Software Engineering. Due to this, the use of software reliability models is fundamental. However, there are many types of models that can be used and none has proved to perform well considering different projects and databases. One way to select the best model for a specific dataset, is to analyse historical data. But, this can consume a lot of effort and time and it is not always a trivial task for most of the software managers. To help in the selection of what reliability model to use, this work presents one approach based on Meta-Learning, a sub-field of Machine Learning. The selection task is seen as a classifier activity, where the classes are the different models. To validate the introduced approach, some experiments were conducted with traditional or parametric models and non parametric ones, such as the models based on Neural Networks and Genetic Programming. These experiments explored some meta-data as variance, inclination, auto-correlation and noise and two kind of classifiers: one based on decision trees and another one based on Neural Networks. The best model is selected based on the Average Error. The obtained results validate the proposed Meta-Learning approach and are very promising.

CAPÍTULO 1

INTRODUÇÃO

A utilização de sistemas computacionais em quase todas as atividades humanas é uma realidade. Este cenário tem como consequência a necessidade de produção de sistemas com alto grau de qualidade. Entende-se por sistemas com qualidade, aqueles que atendem aos requisitos de funcionalidade, eficiência, portabilidade, usabilidade e confiabilidade [28]. No entanto, a construção de software com estes requisitos não é uma tarefa trivial. Especificamente, o requisito de confiabilidade que é considerado por diversos autores como uma das principais características do software [97].

A confiabilidade pode ser definida como a capacidade de um software desempenhar suas funções corretamente por um período de tempo considerando as variáveis do ambiente de execução [28]. Sendo assim, utilizar métodos para estimar ou calcular a confiabilidade do software é uma atividade muito importante na construção de software de qualidade. Avaliar a confiabilidade de software pode auxiliar gerentes de projeto a planejar as atividades de teste e manutenção e a liberação de software com um nível desejado de confiabilidade. A entrega de um software sem que esse nível seja alcançado pode implicar em altos custos para o usuário final, além de uma má reputação para o desenvolvedor [97].

Para avaliar a confiabilidade de software existem alguns modelos. Estes modelos são geralmente classificados de acordo com as características ou informações que são utilizadas na atividade de teste [54, 72] e as suposições que são utilizadas nas suas formulações. Por exemplo, muitos modelos são baseados no tempo [70, 71, 74], isto é, eles consideram o tempo entre falhas observado. Este grupo inclui modelos tradicionais como o modelo de Jelinski-Moranda (JAM) [71] e o modelo Geométrico [70]. Alguns outros modelos, consideram o critério de cobertura de teste [19, 62, 77]. Outros autores também propõem outras classificações para os modelos de confiabilidade. Eles também podem ser classificados em modelos paramétricos e não paramétricos. Os modelos paramétricos são os

modelos que recebem parâmetros que descrevem características dos dados nos quais o modelo irá atuar. Estes parâmetros são utilizados para auxiliar nas avaliações e melhorar a precisão dos modelos. Alguns exemplos de modelos de confiabilidade paramétricos são o JAM e o GEO, mencionados anteriormente.

Outra categoria de modelos é a dos não paramétricos. Estes modelos apesar de receberem parâmetros para ajustes de suas funções na realização das predições, não precisam de informações sobre o tipo da curva dos dados para adequar os cálculos de confiabilidade. Dois exemplos de modelos não paramétricos são os modelos baseados em Programação Genética (PG) [42] e Redes Neurais (RN) [46], que são técnicas de Aprendizado de Máquina.

O Aprendizado de Máquina é uma área da computação que busca o desenvolvimento das técnicas computacionais que possibilitam aos sistemas adquirir conhecimento de forma automática [65, 82, 84]. Modelos de confiabilidade utilizam estas técnicas para buscar o conhecimento nas bases de dados e identificar padrões. Devido a esta característica de aprendizagem, modelos não paramétricos são mais flexíveis a bases de dados com imperfeições e, em geral, apresentam resultados mais precisos.

No entanto, nem sempre um modelo não paramétrico é a melhor opção para diferentes bases de dados. Muito embora diferentes modelos existam, nenhum apresenta-se melhor em todas as bases. O resultado de um modelo de confiabilidade está associado às suposições assumidas para a formulação desse. Quando os dados da base se enquadram nessas suposições, os resultados são mais precisos. Esta dependência das características das bases para aplicação de um modelo de confiabilidade torna a atividade custosa, pois identificar estas características nos dados não é uma tarefa simples para a maioria dos gerentes de software.

Uma abordagem comum na escolha de um modelo de confiabilidade acaba sendo a execução de vários modelos sobre a base de dados e coleta das predições. Após uma avaliação, é definido qual o modelo que apresentou os melhores resultados quanto ao acerto na predição. Este tipo de análise torna a atividade de avaliação de confiabilidade cara, demorada e consumidora de esforço.

Alguns trabalhos foram desenvolvidos no sentido de buscar formas melhores de indicação de um modelo de confiabilidade. Por exemplo, o trabalho de Asad et al [6] introduz uma forma de seleção de modelos de confiabilidade baseada nas fases do ciclo de desenvolvimento de software. Já o trabalho de Khoshgoftaar et al [51] propõe uma abordagem de seleção entre modelos NHPP (*Nonhomogeneous Poisson Process*). No entanto, estes trabalhos não consideram modelos não paramétricos. Para permitir a escolha dentre modelos não paramétricos são necessárias algumas adaptações e extensões.

Para solucionar os problemas desses trabalhos e reduzir o esforço gasto na escolha de um modelo de confiabilidade de software, este trabalho apresenta uma abordagem para a seleção de modelos de confiabilidade que utiliza Meta-Aprendizado.

O Meta-Aprendizado é uma sub-área do Aprendizado de Máquina, na qual o objetivo é fazer com que os algoritmos detectem as características da base de dados e apontem, baseados em dados empíricos, qual o modelo mais adequado. Esta técnica foi originalmente proposta para selecionar o melhor algoritmo para uma base de dados considerando algumas de suas características em um contexto de mineração de dados [101]. Trabalhos recentes incluem modelos de previsão [88] e seleção de séries temporais [80, 81]. Os resultados animadores destes trabalhos são uma motivação para utilizar Meta-Aprendizado no contexto ainda inexplorado de Engenharia de Software, particularmente em confiabilidade de software.

1.1 Objetivos do Trabalho

Dada uma base com informações referentes à confiabilidade de software, este trabalho tem como objetivo principal propor uma abordagem de seleção do melhor modelo a ser utilizado para prever e estimar o nível de confiabilidade do software correspondente. Para isso, o trabalho propõe a utilização de Aprendizado de Máquina e Meta-Aprendizado para decidir qual o melhor modelo, ou seja, o modelo que apresentará a melhor estimativa, a ser aplicado à base de dados considerando algumas de suas características. Com isso, pretende-se facilitar a avaliação da confiabilidade do software e contribuir para o controle e liberação de software de qualidade.

Para validar a abordagem proposta, no contexto de confiabilidade de software, foram realizados experimentos baseados em resultados de diferentes modelos de confiabilidade, incluindo modelos tradicionais e modelos baseados em técnicas de Aprendizado de Máquina, apresentados no trabalho de Costa et al [25]. Considerando os resultados deste trabalho, foram realizados doze experimentos com classificadores que utilizam árvores de decisão e doze experimentos com classificadores que utilizam redes neurais. Os classificadores são utilizados para decidir qual o modelo de confiabilidade a ser utilizado em uma dada base de dados.

1.2 Organização do Trabalho

Este trabalho está organizado conforme segue. No Capítulo 2 são abordados os conceitos e técnicas de Aprendizado de Máquina e Meta-Aprendizado e algumas aplicações de Aprendizado de Máquina em Engenharia de Software. No Capítulo 3 faz-se uma contextualização da área de confiabilidade de software apresentando os principais conceitos, alguns modelos e, em especial, o trabalho de Costa et al [25], o qual forneceu alguns dados que suportam este trabalho. No Capítulo 4 é apresentado o detalhamento do método desenvolvido no trabalho, passos e resultados obtidos com os experimentos de validação. O último capítulo (Capítulo 5) é destinado à conclusão referente aos resultados obtidos e possíveis evoluções da abordagem para trabalhos futuros. O trabalho também contém 12 apêndices com as tabelas geradas e utilizadas nos experimentos de comparação entre os modelos de confiabilidade.

CAPÍTULO 2

APRENDIZADO DE MÁQUINA

Neste capítulo são abordados os principais conceitos de Aprendizado de Máquina, algumas formas de classificação de sistemas de aprendizado automático e algumas aplicações destes sistemas. Uma seção é dedicada a apresentar as formas de Meta-Aprendizado, uma subárea do Aprendizado de Máquina que utiliza *meta-dados* para realização do aprendizado. No final do capítulo, são apresentadas as características da ferramenta Weka que implementa uma variedade de algoritmos de Aprendizado de Máquina e trabalhos que utilizam Aprendizado de Máquina em Engenharia de Software.

2.1 Introdução ao Aprendizado de Máquina

A crescente aproximação dos sistemas computacionais das atividades humanas tem como uma das conseqüências a explosão da quantidade de dados armazenados. A observação dos repositórios de dados pode revelar comportamentos, padrões, tendências e até mesmo contribuir na antecipação de eventos ou situações. No entanto, devido à grande quantidade de informação disponível nas bases de dados, analisar e extrair estas informações de maneira eficiente e confiável pode não ser uma tarefa trivial. Neste contexto, técnicas foram desenvolvidas para que os computadores auxiliem as pessoas nessa atividade. A área da computação que busca o desenvolvimento das técnicas computacionais que possibilitam aos sistemas adquirir conhecimento de forma automática é chamada de Aprendizado de Máquina [65, 82, 84]. Ou seja, qualquer programa que melhora o seu desempenho na execução de uma tarefa através da análise de experiências similares de resolução da tarefa, está executando o Aprendizado de Máquina.

O Aprendizado de Máquina pode ser realizado através de diversas maneiras, mas basicamente três características devem ser identificadas [68]:

- Tarefa a ser aprendida

- Uma medida de desempenho a ser melhorada
- Uma base com experiências desta tarefa.

O primeiro passo para iniciar a construção de um sistema capaz de aprender é selecionar um conjunto de dados de treinamento. A base de treinamento fornece a experiência necessária para o sistema aprender como melhorar o seu desempenho em uma determinada tarefa. Logo, a escolha de uma base de treinamento adequada à tarefa a ser executada é essencial no sucesso ou falha do sistema de aprendizado. A próxima etapa é definir exatamente o tipo de conhecimento que será adquirido e como ele será usado para melhorar a execução da tarefa. Para isto, deve-se escolher uma função alvo e uma forma de representá-la. Esta função alvo é o conceito a ser aprendido. A última etapa é definir um algoritmo que aprenda a função alvo a partir da base de treinamento [68].

Existe uma variedade de formas de sistemas de aprendizado automático que podem ser classificados de acordo com a linguagem de descrição, do modo, paradigma e forma de aprendizado utilizado [84]. As diferentes formas de realização da aquisição de conhecimento ocorrem porque dependendo da tarefa a ser aprendida, da base de treinamento disponível, da forma de captura do conhecimento desta base, os sistemas de aprendizado apresentam diferentes resultados.

A linguagem de representação, ou seja, como representar os exemplos, hipóteses e conhecimentos do domínio é uma forma de classificação dos sistemas de Aprendizado de Máquina. Para descrever estas informações, as seguintes linguagens são utilizadas [84]:

- Linguagem de Representação de Exemplos - LRE
- Linguagem de Representação de Hipóteses - LRH
- Linguagem de Representação de Conhecimento do Domínio - LRC

Outra forma na classificação é o modo de aprendizado: incremental ou não incremental(*batch*). Quando o aprendizado necessita de toda a base de treinamento para acontecer, ele é dito aprendizado não-incremental. Caso contrário, quando a hipótese não precisa ser

construída desde o início e quando novos exemplos são inseridos na base de treinamento, então o aprendizado é dito incremental [84].

2.1.1 Paradigmas de Aprendizado de Máquina

Os paradigmas de Aprendizado de Máquina definem as diferentes formas de aprendizado automático. Os paradigmas são:

1. **Simbólico:** o aprendizado é realizado através de representações simbólicas dos conceitos com a análise de exemplos e contra-exemplos. Estas representações são, geralmente, expressões lógicas, árvores de decisão, regras ou redes semânticas [84].
2. **Estatístico:** neste paradigma de aprendizado, o objetivo é construir um modelo estatístico que representa o mais próximo possível o conceito induzido. Vários destes modelos são paramétricos, nos quais é assumida alguma forma para o modelo e então os parâmetros são ajustados de forma a representar a melhor aproximação sobre o conjunto de dados. As redes neurais são consideradas por alguns autores como exemplo de aprendizado que utiliza o paradigma estatístico [84]. Isso porque as redes neurais precisam ser ajustadas com valores de pesos para as ligações entre os “neurônios” da rede. A técnica de redes neurais será detalhada em uma seção mais adiante deste capítulo. Outro exemplo de métodos estatístico de aprendizado é o Aprendizado Bayesiano, que utiliza um modelo probabilístico baseado no conhecimento prévio do problema combinado com exemplos de uma base de treinamento para determinar a probabilidade final de uma hipótese [84].
3. **Baseado em Exemplos:** este paradigma utiliza a comparação das características do exemplo a ser classificado com uma base de exemplos já classificados, e então assume que a classe do exemplo é a mesma classe daqueles exemplos já conhecidos e que possuem as mesmas características. Quando os exemplos precisam estar carregados na memória para que o classificador possa classificar novos elementos, o sistema é dito *lazy*. O contrário desses sistemas são os sistemas ditos *eagers*. Neste caso, os exemplos são descartados logo após serem utilizados para induzir o

conhecimento. Os dois algoritmos mais importantes deste paradigma são o *Nearest Neighbours (KNN-Algorithm)* (vizinhos mais próximos) [68] e Raciocínio Baseado em Casos (RBC) [84].

4. **Conexionista:** este paradigma é baseado nas inter-conexões entre os atributos representativos de uma classe. Por esta razão, a técnica de redes neurais é mais conhecida deste paradigma [84].
5. **Evolutivo:** este paradigma utiliza uma analogia ao modelo de seleção natural de Charles Darwin, na qual os elementos de uma população evoluem de geração em geração, selecionando naturalmente aqueles mais adaptados ao ambiente e descartando os mais fracos. O paradigma genético utiliza a “evolução” de uma população de indivíduos que competem para solucionar o problema, sendo selecionado aquele que apresentar os melhores resultados [42, 84].

2.1.2 Hierarquia do Aprendizado Indutivo

Uma das maneiras mais comuns de aquisição de conhecimento é através da indução. A indução permite através da inferência lógica sobre fatos/dados a obtenção de conclusões e aquisição de conhecimento. Neste processo de aprendizado, o conhecimento é derivado do raciocínio sobre os dados/experiências já adquiridas. Sendo assim, os conhecimentos gerados através da indução podem ou não representar a verdade, uma vez que as conclusões são totalmente resultantes dos exemplos já conhecidos e os exemplos podem ser insuficientes para gerar uma conclusão totalmente correta.

A Figura 2.1 apresenta a hierarquia do aprendizado indutivo. Este tipo de aprendizado pode ocorrer de maneira supervisionada, na qual é indicada uma classe para cada amostra do repositório de dados, ou não-supervisionada, sem a indicação de uma classe.

Na aprendizagem supervisionada, os algoritmos são preditivos e fornecem como resultado tendências obtidas através de inferências de dados [9, 95]. Ou seja, são fornecidos exemplos ao sistema de aprendizado, sendo que cada exemplo possui uma classe associada, das quais o sistema infere modelos que caracterizam os elementos de uma classe. Dentro



Figura 2.1: Hierarquia do Aprendizado Indutivo adaptada de [84]

da categoria de aprendizado supervisionado, conforme o tipo do atributo-classe podemos dividir a tarefa de aprendizado em classificação e regressão. Quando o atributo-classe é qualitativo e assume valores discretos, então o aprendizado é dito de classificação. Caso o atributo-classe seja quantitativo, isto é, pode assumir valores reais, então a tarefa de aprendizado é dita de regressão.

Já no aprendizado não-supervisionado, as classes dos dados não são conhecidas. Nesta categoria, o objetivo é compor um modelo que procura regularidades nos exemplos, considerando algumas técnicas [9, 82]:

- Associação: busca os relacionamentos entre os atributos do repositório de dados de forma a eleger um atributo determinante na associação com outros atributos. O algoritmo mais famoso é o Apriori [1, 2]. As regras geradas por estes algoritmos são da forma $X \rightarrow A \wedge B$, onde X é chamado de atributo antecedente e A e B são os atributos consequentes. Uma leitura para esta regra é: “Ocorrendo X então ocorre A e B ”.
- Clustering: a partir da definição de uma métrica de similaridade de atributos e uma função de combinação destas métricas de atributos em uma métrica global, esta técnica realiza o agrupamento das instâncias de um repositório de dados. Este agrupamento pode revelar características intrínsecas de um grupo de instâncias de uma base [95].

2.1.3 Técnicas de Aprendizado de Máquina

Uma característica importante dos algoritmos de Aprendizado de Máquina é a capacidade de revelar padrões/conhecimentos corretos relativos a uma base, mesmo que esta contenha dados com imperfeições ou ausência de algumas informações [25]. Esta capacidade é complementada por técnicas de pré-processamento e transformação dos dados que são aplicadas nas bases de dados a fim de aumentar a qualidade dos mesmos. Realizadas as tarefas de tratamento e preparação dos dados, a próxima etapa é a aplicação dos algoritmos de aprendizado. Dentro dos paradigmas de aprendizagem de máquina, existem as técnicas ou algoritmos que implementam a forma de aprendizado. Algumas técnicas são:

- Árvores de Decisão
- Programação Genética
- Redes Neurais

Geralmente, a metodologia utilizada na aprendizagem é dividir a base de dados em dois subconjuntos: uma base para descoberta dos padrões que é chamada de base de treinamento e outra onde o conhecimento adquirido na base anterior é aplicado para verificação de sua validade. Normalmente, o repositório de dados é dividido de forma que $2/3$ dos dados estejam na base de treinamento e o restante ($1/3$) como base de verificação ou teste [95]. No entanto, quando a base na qual está sendo realizado o aprendizado é reduzida, outras técnicas podem ser utilizadas. Neste trabalho utilizamos a técnica denominada *leave-one-out* e que será descrita no Capítulo 4.

2.1.3.1 Árvores de Decisão

Uma árvore de decisão é uma representação formada por nós interligados, onde os nós podem ser *nós-folhas* ou *nós de decisão*. Os nós estão todos interligados representando o caminho que deve ser seguido para alcançar os nós-folhas.

Alguns exemplos de algoritmos de aprendizado supervisionado de classificação que apresentam árvores de decisão como resultado são: Id3, J48, ADTree e o C4.5 [82], principal classificador e descendente do Id3. Para que um conjunto de dados possa ser classificado pelo algoritmo C4.5, ele deve poder ser expresso em termos de atributos, conter classes pré-definidas e discretas para que o C4.5 possa realizar a aprendizagem supervisionada e, dados suficientes para identificação dos padrões. Como resultado, o algoritmo produz uma árvore de decisão onde as folhas representam classes e os nós superiores às folhas são testes que devem ser aplicados a um valor de um atributo para decidir qual caminho até as folhas da árvore deve ser seguido.




Figura 2.2: Árvore de Decisão do C4.5

A Figura 2.2 mostra um exemplo de árvore de decisão. Para alcançar as folhas, devem ser realizados testes sobre os valores dos atributos dos nós a5, a2 e a4. Conforme os valores destes atributos, a árvore indica um caminho para definição da classe (c0 e c1 por exemplo). Algumas vantagens do C4.5 são o uso reduzido de memória, simplicidade na interpretação das regras e seleção automática dos atributos relevantes.

2.1.3.2 Programação Genética

A Programação Genética (PG) é um outro método de Aprendizado de Máquina. Ela é uma técnica da área de estudo chamada de Computação Evolucionária que compõe o paradigma genético de resolução de problemas e utiliza os princípios apresentados por Darwin para selecionar entre uma coleção de programas, qual deles é mais adequado para solução

de um dado problema. Inicialmente proposto por John Koza [53] que baseou suas idéias nos trabalhos relacionados a Algoritmos Genéticos de John Holland [42], a Programação Genética tem sido pesquisada em trabalhos de Inteligência Artificial e Aprendizado de Máquina. Diferentemente dos Algoritmos Genéticos nos quais os indivíduos da população são usualmente representados por *strings* de bits, a programação genética utiliza programas de computador geralmente codificados na forma de árvore.

Os algoritmos de PG utilizam uma função heurística chamada de *fitness* ou aptidão que recebe um programa como parâmetro de entrada para especificação da hipótese e retorna um número que indica quão próximo a solução encontrada está da solução desejada. A estrutura geral dos algoritmos de PG é uma árvore onde os nodos são funções ou um terminal. A cada interação do algoritmo de PG, uma nova população de programas é criada e substitui a população anterior. Para iniciar a execução do algoritmo de PG uma população de programas é gerada aleatoriamente. Após submeter a população inicial à função de *fitness*, alguns programas são submetidos a um dos operadores: reprodução, *crossover* ou mutação [25].

O operador de reprodução replica o programa para a próxima geração, o *crossover* (cruzamento) combina dois programas gerando dois descendentes, e o operador de mutação seleciona aleatoriamente uma parte do programa e a substitui por uma nova sub-árvore. Todo o comportamento de um algoritmo de PG é determinado pelos parâmetros que indicam a probabilidade de aplicação dos operadores, o número de repetições do algoritmo, limitação e controle de como as buscas na árvore serão realizadas, o tamanho da população, entre outros. O algoritmo é executado até que a solução desejada seja encontrada ou o número máximo de gerações tenha sido alcançado. Como resultado, o programa que representa a melhor solução do problema é encontrado de acordo com os parâmetros e a função de *fitness*.

2.1.3.3 Redes Neurais

Além da PG, outra técnica que vem sendo utilizada são as redes neurais artificiais. As redes neurais são modelos matemáticos representados através de uma estrutura de unidades

interligadas. A representação destes modelos é associada à estrutura neural dos organismos inteligentes que adquirem conhecimentos através de experiências, onde as unidades são os neurônios e as ligações são as sinapses. Para cada sinapse é atribuído um valor numérico ou peso. Em uma rede neural, o programa está distribuído por toda a rede e armazenado em cada neurônio. Durante a fase de aquisição de conhecimento, os pesos das sinapses são ajustados até que a saída desejada seja alcançada. Quando termina a execução, os pesos e valores obtidos em cada neurônio constituem o programa da rede e a solução do problema [25, 46].

A topologia típica de redes neurais é chamada de multi-camadas com propagação direta. Neste tipo de topologia, existe a camada de apresentação do resultado (camada de resposta), as camadas intermediárias onde é realizado o processamento e a camada de entrada que recebe os dados para processamento. Neste tipo de topologia, a informação segue da camada de entrada até a camada de saída sem realizar ciclos. Exemplos de rede neural são apresentados nas Figura 2.3 e 2.4, onde E representa a entrada, S a saída e cada neurônio tem a sua função de transferência. Um exemplo de neurônio é exibido na Figura 2.5




Figura 2.3: Uma Estrutura de Rede Neural

Para realizar o aprendizado existem diversos algoritmos, sendo que o mais conhecido é o *back-propagation learning* [45]. Neste algoritmo, os dados são entregues à camada de entrada que repassa a informação para as demais camadas e um resultado é gerado na camada de resposta. A saída é comparada com a resposta desejada e é calculado um valor de erro. Este valor de erro é utilizado para calcular os novos pesos da camada de resposta. O algoritmo prossegue calculando os erros e repassando os pesos entre as




Figura 2.4: Uma Estrutura de Rede Neural MultiCamadas




Figura 2.5: Um Neurônio de uma Rede Neural

camadas em direção à camada de entrada. Este procedimento é executado até que o resultado esperado esteja estabilizado e a solução final seja alcançada. Para executar o aprendizado em uma rede neural, o usuário deve configurar a estrutura da rede informando o número de camadas, o número de neurônios e a função associadas a eles. Dependendo do algoritmo alguns outros parâmetros são necessários como um critério de parada, taxa de aprendizagem e pesos iniciais.

2.2 Meta-Aprendizado

Meta-Aprendizado é uma subárea do Aprendizado de Máquina que consiste na aplicação de algoritmos sobre os dados (meta-dados) obtidos de experimentos resultantes da aplicação do Aprendizado de Máquina, ou seja, as informações aprendidas são submetidas a um algoritmo com um intuito de identificar qual modelo de aprendizagem é mais adequado para uma dada base de dados [101, 103] considerando estas características. Os algoritmos de aprendizagem são baseados em algumas suposições que se aplicam somente a alguns tipos de bases. Através da utilização de alguns tipos de meta-dados, como propriedades dos algoritmos de aprendizado e características do problema a ser resolvido, é possível

apontar, mesclar ou modificar os algoritmos de aprendizado a serem utilizados na busca das informações. Esta visão de Meta-Aprendizado é chamada de descoberta de meta-conhecimento. Algumas outras visões de meta-aprendizado são:

- *Stacked generalisation* [101, 103]: funciona combinando vários algoritmos de aprendizagem. Os meta-dados são compostos das previsões destes algoritmos e então um outro algoritmo é executado sobre os meta-dados para identificar qual combinação de algoritmos traz melhores resultados.
- *Boosting* [101, 103]: semelhante a *Stacked generalization*, porém usa o mesmo algoritmo diversas vezes onde os exemplos das bases de treinamento recebem pesos diferentes a cada execução. Isto produz previsões diferentes onde o foco é direcionado a um subconjunto de dados. A combinação destas previsões tende a melhorar os resultados.
- Seleção de tendência dinâmica (*Dynamic Bias Selection*) [101, 103]: funciona alternando características de suposições dos algoritmos de aprendizagem a fim de ajustá-los a um determinado problema. As alterações podem ocorrer na representação das hipóteses, função heurística ou parâmetros.
- Transferência indutiva [101, 103]: tenta aperfeiçoar o aprendizado a partir de dados obtidos de aprendizados anteriores. O processo de aprendizado está sempre em desenvolvimento.

O Meta-Aprendizado foi inicialmente proposto para selecionar o melhor algoritmo para uma base de dados baseado em características dos dados em um contexto de mineração de dados [101]. Trabalhos recentes incluem modelos de previsão de séries temporais [88] e modelos de seleção de séries temporais [80, 81].

2.3 Weka

O sistema Weka (*Waikato Enviroment for Knowledge Analysis*) [102] foi desenvolvido na Universidade de Waikato, Nova Zelândia. Este software implementa um grande conjunto

de ferramentas para preparação dos dados, Aprendizado de Máquina e validação/verificação dos resultados.

Inicialmente, as aplicações do Weka foram direcionadas para problemas de agricultura, no entanto, sua aplicação estendeu-se para diversas áreas onde há a necessidade da mineração de dados e descoberta de padrões em grandes quantidades de dados. Por ter sido desenvolvido por uma universidade, a maioria dos módulos do sistema são resultados de teses e dissertações na área de descoberta de conhecimento. Outro fator importante para sua aceitação e utilização em diversos trabalhos acadêmicos é a linguagem Java que foi utilizada para sua construção, permitindo ao sistema um bom nível de portabilidade.

O Weka dispõe de uma interface gráfica para a maioria de suas funções, permitindo ao usuário a seleção da fonte de dados, remoção dos atributos e seleção automática e manual de atributos que serão utilizados na descoberta de conhecimento. Além da preparação dos dados, o Weka oferece alguns algoritmos classificadores como o ZeroR, o Id3, o J48 e o PART, algoritmos de descoberta de regras de associação como o Apriori [1, 2], algoritmos baseados em redes neurais (*MultilayerPerceptron*) e funções de *Clustering*. Além da interface gráfica, o Weka disponibiliza uma série de APIs (*Application Program Interface*) que permitem a utilização de seus algoritmos.

2.4 Aprendizado de Máquina em Engenharia de Software

O crescimento das pesquisas no campo de Aprendizado de Máquina possibilita a aplicação e a realização de experimentos em subáreas da Engenharia de Software. Técnicas de Aprendizado de Máquina podem auxiliar analistas no planejamento, no acompanhamento e monitoração de projetos, na atividade de teste e manutenção entre outras.

Técnicas de Aprendizado de Máquina são particularmente úteis para compreender o domínio de um dado problema e domínios para os quais programas precisam se adaptar a diferentes condições não muito claras. Os problemas da Engenharia de Software estão relacionados ao desenvolvimento e manutenção de software, e em geral possuem essas características. Portanto, a Engenharia de Software constitui uma área fértil de problemas para a aplicação de Aprendizado de Máquina [104].

Muito autores têm discutido possíveis aplicações de Aprendizado de Máquina na Engenharia de Software em publicações que apresentam o atual estado da arte dessas aplicações. Zang e Tsai [104] apresentaram uma tabela (Tabela 2.1) de classificação para esses trabalhos de acordo com o objetivo e a tarefa da Engenharia de Software envolvida. Os métodos de Aprendizado de Máquina são apresentados na Tabela 2.1 utilizando siglas, definidas tais como apresentado na Tabela 2.2

A Tabela 2.1 exibe uma lista de trabalhos separados por método de aprendizado, qual atividade de aplicação na engenharia de software e o tipo da atividade. Percebe-se analisando a tabela que a maior parte dos trabalhos utilizam as técnicas de Aprendizado de Máquina para geração de casos de teste e para previsão, e principalmente nas atividades de planejamento de projeto. São poucos os trabalhos existentes que visam a estabelecer modelos para avaliar a confiabilidade de software.

2.5 Considerações Finais

Este capítulo fez uma breve explanação sobre os principais conceitos e técnicas relacionados ao Aprendizado de Máquina. Técnicas de Aprendizado de Máquina são importantes na identificação de padrões, tendências, conhecimentos que estão distribuídos em bases de dados. Estas técnicas são divididas dentro de paradigmas que as classificam de acordo com a maneira de realizar o aprendizado.

Além das técnicas, este capítulo descreveu uma sub-área do Aprendizado de Máquina particularmente importante para este trabalho chamada Meta-Aprendizado. Esta sub-área de estudo busca adquirir conhecimento a partir de dados resultantes de algum outro aprendizado. O Meta-Aprendizado tem sido recentemente utilizado para obter modelos de previsão de tempo no contexto de mineração de dados. Não tendo sido ainda aplicado na área de Engenharia de Software.

A aplicação de Aprendizado de Máquina tem um interessante campo na Engenharia de Software, podendo ser aplicado em atividades como planejamento de projeto, estimativa de custo, geração de dados de teste e confiabilidade. Especialmente a confiabilidade de software é uma atividade muito crítica e de particular interesse deste trabalho. En-

Tabela 2.1: Aplicações de Aprendizado de Máquina na Engenharia de Software

Tipo de Atividade	Atividade na Eng. de Software	Métodos de Aprendizado de Máquina
Previsão	Qualidade de Software Tamanho do Software Custo de Desenvolvimento de Software Esforço de Projeto/Software(desenvolvimento) Esforço da Atividade de Manutenção Análise dos Recursos de Software Custo de Correção Confiabilidade de Software Defeitos Reusabilidade Tempo de Disponibilização de Versão Testabilidade de Módulos	PG([33]), RN([43], [50], [57]), CBR([32], [36]), DT([14],[78]), CL([5]), ILP([23]) RN,PG([30]) DT([13]), CBR([15]), BL([21]) CBR([93],[100]), DT,RN([98]), GA+RN([94]), RN,CBR RN,DT([44]) DT([92]) DT,ILP([4]) RN([47]) BL([34]) DT([63]) RN([29]) RN([49])
Descobertas de Propriedade/Modelo	Constantes de Programas Identificação de Objetos em Programas Processamento de Modelos	ILP([12]) RN([87]) RN([24]), EBL([37])
Transformação	Transformação de Programas Seriais em Paralelos Melhorando Modularidade de Software Mapeamento de aplicações OO para ambientes distribuídos heterogeneamente	PG([85],[86]) CBR+RN([91]) GA([20])
Geração e Síntese	Casos e Dados de Teste Agentes de Software Conhecimento de Reparação de Projeto Projeto de Esquemas Estruturas de Dados Programas/Scripts Gerenciamento de Cronograma	ILP([10]), GA([64],[66]) PG([83]) CBR+EBL([7]) IBL([40]) PG([56]) IBL([11]), CL,AL([67]) GA([16])
Construção e Manutenção de Bibliotecas Reutilizáveis	Computação de Similaridade Pesquisa Ativa Custo de Re-Trabalho Representação de Conhecimento Localização e Adaptação de Software para Especificação Generalização de abstrações de programa Agrupamento de Componentes	CBR([75]) IBL([31]) DT([8]) CBR([35]) CBR([48]) EBL([41]) GA([59])
Aquisição e Recuperação de Especificação	Derivação de Especificações dos Objetivos e Requisitos de Sistemas Extração da Especificação do Software Aquisição de Conhecimento para Especificação Refinamento de Argumentação Aquisição e Manutenção de Especificação consistente com cenários	CL([55]) ILP([22]) DT,RN([76]) EBL([38],[39])
Conhecimento e Gerenciamento de Desenvolvimento	Coleta e Gerenciamento de Conhecimento de Desenvolvimento de Software Captura e Reutilização de Conhecimento de Projeto	CBR CBR([58])

tretanto, são poucos os trabalhos que utilizam Aprendizado de Máquina para avaliar a confiabilidade de software. Este trabalhos são descritos no próximo capítulo dedicado a esse tema. Neste próximo capítulo são apresentados os principais conceitos de confiabi-

Tabela 2.2: Tipos de Métodos de Aprendizado de Máquina

Tipo	Descrição	Algoritmos
AL (EBL)	Aprendizado Analítico	Prolog-EBG
BL	Aprendizado <i>Bayesian</i>	MAP, BOC, Gibbs, NBC
CL	Aprendizado de Conceitos	Eliminação de Candidato
DT	Árvores de Decisão	ID3, C4.5, Assistente
GA	Algoritmos Genéticos	<i>Prototypical</i>
PG	Programação Genética	GA/PG algoritmos
IBL	Aprendizado baseado em Instâncias	K-NN, LWR, CBR
ILP	Programação de Lógica Indutiva	SCA, FOIL, PROGOL, resolução inversa
RN	Redes Neurais	<i>Back-Propagation</i>
IAL	Aprendizado Analítico e Indutivo	KBNN, EBRN, FOCL
RL	Aprendizado Reforçado	Q, TD

lidade de software, os principais modelos e a descrição de um trabalho de comparação entre modelos paramétricos (JAM e GEO) e não paramétricos (PG e RN). Este trabalho é utilizado de base para os experimentos de validação descritos no Capítulo 4.

CAPÍTULO 3

CONFIABILIDADE DE SOFTWARE

O estreito relacionamento da maioria das atividades humanas com sistemas computacionais tem como consequência inevitável a dependência da disponibilidade quase que permanente destes sistemas e principalmente da confiabilidade dos resultados gerados por eles. Por isso, muitos autores têm considerado a confiabilidade de software como uma das principais características da qualidade de software [97].

Este capítulo é dedicado à apresentação dos conceitos relacionados à confiabilidade de software, seus principais modelos, inclusive os que utilizam Aprendizado de Máquina.

3.1 Definição

Desenvolver produtos de alta qualidade é ainda um desafio para a indústria de software. A dificuldade é oriunda da própria definição de software como uma entidade lógica, que nem sempre pode ser representada por formalismos matemáticos que atestam o seu funcionamento. Além disso, na maioria dos casos não é possível garantir que um software está completamente correto através da atividade de teste. Isto porque ao construir um software, diversas variáveis e caminhos de execução são determinantes e testar todas as situações possíveis na maioria das vezes é impossível [28].

Considerando qualidade de software em um sentido mais amplo, a ISO9126 [28] divide a qualidade de software em: funcionalidade, eficiência, portabilidade, usabilidade e confiabilidade. Dentre estes fatores, a confiabilidade tem consenso entre pesquisadores como um dos principais componentes na medição da qualidade do software devido ser um fator que pode ser medido e estimado com base em dados históricos, permitindo a classificação das falhas de software. Além disso, a confiabilidade é de grande importância na qualidade de software, pois quando um software não é confiável, de nada adianta que os outros fatores sejam satisfatórios. Por outro lado, medir a confiabilidade de um software não é

uma tarefa trivial.

A preocupação com confiabilidade surgiu em 1967 com Hudson [28], e a partir dos anos 70, fundamentos da teoria de confiabilidade aplicados a hardware começaram a gerar estudos na criação de modelos para confiabilidade de software. Na década de 80, surgiram diversos modelos para confiabilidade de software.

O objetivo destes modelos é atribuir um número, grau de confiabilidade, ao software baseado em análises estatísticas do comportamento do software. Sendo assim, a confiabilidade representa o nível de qualidade do ponto de vista do usuário. Podemos definir como confiabilidade de software a capacidade de um software desempenhar as suas funções corretamente por um período de tempo considerando as variáveis de ambiente de execução [28].

De uma maneira geral, são três os fatores que garantem a confiabilidade de um software:

- Evitar a introdução de erros durante a construção.
- Realizar testes e depuração para remoção de defeitos.
- Garantir um ambiente de execução do sistema adequado.

Uma das primeiras preocupações na análise de confiabilidade de um software é como realizar a medição. Diversos autores propuseram métricas e formas para atribuição de um valor de confiabilidade de um software. No entanto, muitos artigos têm considerado como variável para cálculo as falhas do software [28]. Logo, é necessária a realização de uma atividade para contagem e medição da frequência com que elas ocorrem. A partir destes dados, é possível realizar uma estimativa e previsão do grau de confiabilidade. As análises de confiabilidade consideram o número de falhas ao invés do número de defeitos pelo fato de que as falhas são uma manifestação de um defeito causado por entrada de dados e que provoca uma saída diferente da esperada. Enquanto isso, defeitos são trechos de códigos imperfeitos, incompletos ou até mesmo extra que podem causar uma falha [27].

A ocorrência de uma falha em um sistema é um evento totalmente imprevisível e por isso aleatório. Devido a esta natureza não determinística das ocorrências das falhas, o

estudo da confiabilidade está intimamente associado à teoria de probabilidades. Para software, considera-se como grau de confiabilidade o número resultante do cálculo da probabilidade de dada uma entrada, o software produzir uma saída correta sem que ocorra falhas durante a sua execução [28].

Como a medição da confiabilidade de um software está ligada à teoria das probabilidades, e a ocorrência de falhas é um evento aleatório no qual quanto maior a ocorrência de falhas menos confiável é o software. A análise da frequência das falhas é uma variável interessante de ser analisada no decorrer do tempo. Conforme o tempo transcorre, o número de falhas diminui e o intervalo de descoberta das falhas aumenta. Pois enquanto o sistema vai sendo desenvolvido, as falhas vão sendo corrigidas e quando não há o aparecimento de novas falhas, a tendência da curva é uma exponencial.

3.2 Modelos de Confiabilidade

Na seção anterior foram apresentados os principais conceitos associados à confiabilidade de software. Nesta seção são apresentados os principais tipos de modelos de confiabilidade e são descritos detalhadamente dois modelos tradicionais e bastante conhecidos para o cálculo de confiabilidade: Jelinski-Moranda (JAM) [71] e Geométrico (GEO) [70].

3.2.1 Modelagem

A confiabilidade é uma característica do software que depende de três principais fatores, conforme citado na seção anterior. A confiabilidade está diretamente ligada à fase de desenvolvimento onde são introduzidos defeitos, são realizados testes para sua descoberta e, posterior remoção. Além disso, a confiabilidade do software está associada ao seu ambiente de execução. Sendo assim, a modelagem da confiabilidade apropria-se principalmente destes fatores.

A introdução de defeitos está associada a ferramentas e técnicas utilizadas no desenvolvimento e também a qualidade do time de desenvolvimento. A contagem de defeitos deve ser realizada através da identificação de uma falha. Já a remoção de defeitos de-

pende do período de execução do software e da maneira de execução. Apesar do período de execução estar associado a esta característica, somente faz sentido considerá-lo caso o perfil do usuário explore diversas funcionalidades do software.

Como a ocorrência de uma falha é um processo não determinístico, este evento é tratado como um processo aleatório no decorrer do tempo. Os modelos de confiabilidade tentam determinar a probabilidade da ocorrência de falhas de software [28]. Alguns destes modelos calculam a probabilidade da ocorrência de falhas com relação ao tempo. As medidas de confiabilidade podem colaborar no desenvolvimento de software no sentido de aprimorar, estimar e planejar o processo de desenvolvimento e a qualidade do produto final.

Apesar dos modelos apresentarem uma estimativa de valor de confiabilidade, estes modelos devem ser considerados como ferramentas adicionais à gerência de software. Neste sentido, os modelos existentes devem ser previamente analisados e escolhidos de acordo com os dados disponíveis para o cálculo da confiabilidade. Os modelos permitem estimar o grau de confiabilidade atual e prever o grau de confiabilidade futuro de um sistema, ajudando a decidir quanto de esforço é necessário para que o sistema atinja um grau de confiabilidade dentro de um prazo [25, 28].

Existem diversos tipos de modelos para a confiabilidade de software. As principais classificações dos modelos são:

- Modelos de introdução de defeitos.
- Modelos de domínio dos dados de entrada.
- Modelos de domínio do tempo.
- Modelos de cobertura de teste.

Existem diversas técnicas para abordagem dos modelos de introdução de defeitos. A abordagem de Mills [27] consiste em implantar um número x de defeitos no sistema. Após a inserção dos defeitos, o sistema é testado por uma equipe. Realizados os testes, os defeitos identificados são separados entre defeitos inseridos e defeitos que já existiam

no software. A partir desta separação, é calculado o percentual de defeitos inseridos que foram descobertos com relação ao número x de defeitos inseridos. Este percentual é considerado como o percentual de defeitos existentes descobertos durante a atividade de teste em relação ao número de defeitos.

Além de Mills, outros autores também propuseram variações desta técnica para estimar o número de defeitos de um software e assim calcular o grau de confiabilidade. No entanto, estes modelos são criticados quanto à dificuldade da inserção de defeitos artificiais no sistema e em termos de dificuldade de detecção em relação aos defeitos existentes. Esta situação causa a subestimação do número real de defeitos existentes. Outro fator de crítica é que os modelos baseados na introdução de defeitos não consideram o tempo como variável de influência no modelo [28].

Os modelos de domínio de dados de entrada são baseados na divisão do domínio para estimar a confiabilidade. Estes modelos calculam a confiabilidade calculando o número de execuções com sucesso dividido pelo número total de execuções. Algumas variações deste modelo, são a subdivisão do domínio de dados e a distribuição de probabilidades de dados de entrada pertencerem a estas subdivisões considerando o perfil operacional do usuário. Nesta abordagem, o número de casos de testes deve ser dividido de maneira a atender à probabilidade de execução de cada faixa do domínio de dados [28].

Os modelos de domínio do tempo são baseados na ocorrência de falhas no transcorrer do tempo para o cálculo da confiabilidade. Estes modelos utilizam o intervalo de tempo entre ocorrência de falhas e o número de falhas que ocorrem dado um intervalo de tempo. Estas duas abordagens podem estimar o tempo para ocorrência da próxima falha em um sistema e o número de falhas previsto para o próximo intervalo de tempo. Apesar de existirem diversos modelos de domínio de tempo, não há uma definição de qual o melhor modelo para um dado conjunto de dados. A orientação é aplicar o maior número de modelos para identificar qual modelo é mais adequado aos dados disponíveis [28]. Alguns modelos baseados no tempo podem ser encontrados em [70, 71, 74].

Ao contrário dos tipos de modelos apresentados acima, os modelos de cobertura de teste são baseados na cobertura do código executado. Esta abordagem tem a vantagem de

fornecer um valor de confiabilidade considerando apenas trechos de código efetivamente executados, evitando assim a superestimação da confiabilidade causada pela saturação da execução de casos de testes. Alguns modelos de confiabilidade baseados na cobertura de teste são o modelo tipo binomial baseado em cobertura (MBBC), o modelo tipo Poisson baseado em cobertura (MBBC) e o modelo de categoria de falhas infinita baseado em cobertura (MFIBC) [27, 28]. Outros modelos baseados em cobertura de teste são encontrados em [19, 62, 77].

Nas próximas seções serão abordadas as principais características de dois modelos baseados no tempo: JAM e GEO. Estes dois modelos foram os primeiros a serem empregados na determinação de confiabilidade de software e são os mais conhecidos e utilizados.

3.2.2 Modelo de Jelinski-Moranda (JAM)

O modelo de Jelinski-Moranda (JAM) [28, 71], que recebe o nome de seus autores, foi desenvolvido para o projeto Apolo e considera a idéia básica de que o tempo entre falhas segue uma distribuição exponencial onde o parâmetro é proporcional ao número de defeitos restantes no software. Sendo assim, o tempo médio entre $i-1$ e a i -ésima falha é dado por:

$$Tempo - Medio = \frac{1}{\theta(N - i + 1)} \quad (3.1)$$

Onde N é o número de falhas no início do teste e θ é a constante de proporcionalidade.

A distribuição exponencial é a distribuição de probabilidades mais conhecida e utilizada devido a sua simplicidade e grande aplicabilidade. Ela é um bom modelo para descrever o tempo T entre a ocorrência de duas falhas consecutivas. A função de distribuição de probabilidade tem a forma:

$$F(t) = 1 - \lambda e^{(-\lambda t)} \quad (3.2)$$

Onde λ é o parâmetro que indica a taxa de falhas.

O JAM considera que o software deve ser operado nas mesmas condições que as predições foram realizadas, que não há a introdução de novos defeitos durante a remoção de um outro, as falhas são independentes, todos os defeitos têm a mesma chance de ser identificados dentro de uma mesma classe de dificuldade e que a taxa de detecção de defeitos é proporcional ao número de defeitos correntes no software e que permanece constante entre a ocorrência das falhas. O modelo de Jelinski-Moranda é classificado como categoria de falhas finitas, de classe exponencial e do tipo binomial segundo a classificação de Musa [72] e necessita do tempo de ocorrência entre falhas para realizar a predição de confiabilidade [27].

3.2.3 Modelo Geométrico (GEO)

Diferentemente do modelo JAM, o modelo geométrico (GEO) [28, 70] proposto por Moranda, não considera um número fixo de defeitos no sistema e não assume que eles tenham possibilidades iguais de ocorrer. O GEO admite que conforme a atividade de teste vai progredindo, os defeitos são mais dificilmente detectados e o tempo entre as falhas cresce seguindo uma distribuição exponencial. No início, o modelo assume a taxa de falhas igual a uma constante que decresce geometricamente conforme as falhas vão sendo identificadas. Desta maneira, o modelo considera como de grande impacto as falhas detectadas no início e dificulta a redução da taxa de falhas no final da busca [27].

Este modelo considera que o grau de confiabilidade calculado seja representativo, o software deverá ser operado de maneira semelhante às condições que a confiabilidade foi calculada, que os defeitos têm chances iguais de serem identificados dentro de uma mesma classe de dificuldade, que o número de defeitos é finito, que as falhas detectadas são independentes e que a taxa de detecção de defeitos forma uma progressão geométrica e é constante entre os intervalos de detecção de defeitos. Além disso, o modelo assume que o tempo entre falhas segue uma distribuição exponencial cuja média decresce geometricamente. Para realizar o cálculo de confiabilidade é necessário fornecer o tempo que os defeitos foram encontrados e o tempo entre as identificações. O modelo geométrico não

estima o número de defeitos, apenas o tempo médio entre falhas [27].

3.2.4 Outros Modelos

Existem diversos outros modelos para cálculo de confiabilidade. Um dos primeiros modelos a ser utilizado para confiabilidade de software foi o modelo de Weibull [69]. Este modelo foi originalmente proposto para modelagem de confiabilidade de hardware e posteriormente adaptado para software. Dois outros modelos são os modelos binomial e Poisson.

O modelo de Poisson considera que as falhas de software seguem uma distribuição de Poisson no tempo. Em um processo de Poisson as seguintes características são observadas [99]:

- A ocorrência dos eventos em um intervalo de tempo é independente.
- Um número infinito de ocorrências de um evento deve ser possível no intervalo.
- A probabilidade da ocorrência de um único evento em um dado intervalo de tempo é proporcional ao tamanho deste intervalo.
- Em uma porção infinitesimal do intervalo, a probabilidade de mais de uma ocorrência do evento é desprezível. Na distribuição de Poisson a média e a variância são iguais a λ , que representa a taxa com que eventos são observados. A distribuição de Poisson é dada por:

$$f(x) = \frac{(e^{-\lambda} \cdot \lambda^x)}{x!} \quad (3.3)$$

Onde x é o parâmetro da distribuição (média de ocorrência de x) e e é o número de Euler (2.71182818...)

Quando se faz um grande número de observações, e quando o evento tem uma pequena probabilidade de ocorrer, o número total de eventos tem distribuição aproximadamente Poisson cuja taxa de ocorrência é dada por:

$$\lambda = np \quad (3.4)$$

Onde n é o número de observações e p é a probabilidade de ocorrer o evento [99].

Enquanto isso, o modelo binomial considera que o tempo entre falhas segue uma distribuição binomial e sempre que os defeitos são encontrados são removidos imediatamente [27]. Na distribuição binomial, o resultado de uma variável aleatória está associado a apenas dois resultados (sucesso ou fracasso), como por exemplo o lançamento de uma moeda [99]. A fórmula da distribuição binomial é dada por:

$$b(x, n, p) = C_n^x p^x (1 - p)^{n-x} \quad (3.5)$$

Onde x é o número de tentativas bem sucedidas, n é o número de tentativas independentes e p é a probabilidade de sucesso em cada tentativa.

Além desses modelos, alguns outros são o modelo extensão de Lipow [60], Schick-Wolverton [89] e o modelo de Schneidwind [90].

3.2.5 Modelos de Confiabilidade Baseados em Aprendizado de Máquina

Muitos autores têm explorado o uso de Aprendizado de Máquina para estabelecer modelos de confiabilidade. Redes Neurais é uma das técnicas mais utilizadas, havendo na literatura diversos trabalhos explorando diferentes tipos de redes [3, 47, 96].

A técnica de Programação Genética foi inicialmente explorada por Costa et al [26]. Essa abordagem foi avaliada em experimentos descritos em [25]. Estes experimentos exploram modelos paramétricos e não paramétricos analisando cinco medidas (desvio máximo, tendência média, erro médio, erro de estimativa e coeficiente de correlação) para verificação de quais modelos apresentavam melhores resultados sobre bases de dados de pro-

jetos de diferentes características. Os modelos não paramétricos têm uma tendência maior de adaptabilidade e conseqüentemente de gerar melhores resultados do que os modelos tradicionais como o JAM [71] e o GEO [70]. Os principais modelos não paramétricos escolhidos pelos autores foram os baseados em Redes Neurais (RN) e Programação Genética (PG).

Foram utilizados 16 *datasets* disponibilizados pelo centro de dados e análises de software (DACS sigla em inglês) [73]. O DACS pertence ao Departamento do Defesa e foi criado como uma fonte de suporte à comunidade de desenvolvimento de software. Um dos serviços prestados pelo DACS é a disponibilização de um conjunto de *datasets* relativos a 16 projetos com o número de falhas e o tempo de identificação das falhas. Estes *datasets* foram montados por John Musa dos Laboratórios Bell com o objetivo de auxiliar os analistas na monitoração da atividade de testes, elaboração de cronogramas e ajudar na validação dos modelos de confiabilidade de software. Os dados foram coletados em projetos realizados em 1970 e incluem projetos de tempo real, processadores de texto, comerciais e aplicações militares [73]. Os *datasets* são compostos de quatro atributos: nome do projeto, número da falha, intervalo de tempo entre a falha anterior e a falha que está sendo reportada e o dia em que a falha ocorreu considerando os dias úteis referentes ao início da fase de desenvolvimento corrente ou ao período de início de coleta dos dados.

Neste experimento, para cada um dos modelos (JAM, GEO, RN, PG) foram calculadas cinco medidas conforme segue:

- Desvio Máximo (md): é a maior diferença encontrada entre o valor estimado pelo modelo e o valor observado.
- Tendência Média (ab): é a medida de tendência a superestimar ou subestimar o número de defeitos.
- Erro Médio (ae): é a medida de quão bem o modelo previu através da fase de testes.
- Erro de Estimativa (pe): é o erro da última estimativa.
- Coeficiente de Correlação (cc): representa quanto o valor estimado corresponde ao

valor observado. O valor 1 de coeficiente de correlação significa que o valor previsto representa completamente o valor observado.

A partir da aplicação dos modelos às 16 bases de dados, foram coletados os valores destas medidas e compostas as Tabelas 3.1, 3.2, 3.3, 3.4 e 3.5. Os resultados da comparação das tabelas mostram que nenhum dos modelos apresentou sempre os melhores resultados para todas as bases. No entanto, os modelos não paramétricos mostraram-se mais flexíveis e se adaptaram melhor às bases de dados do que modelos tradicionais como o JAM e o GEO que em alguns casos não convergiram (bases 14C, SS1A, SS2, SS3).

Tabela 3.1: Modelo de Jelinski–Moranda

<i>Base</i>	<i>mdd</i>	<i>pe</i>	<i>ab</i>	<i>ae</i>	<i>cc</i>
1	27.01	27.01	6.37	14.39	97.50
14C	-	-	-	-	-
17	14.40	5.89	4.89	6.21	99.46
2	30.73	30.73	21.68	22.42	96.93
27	34.05	34.05	8.90	18.50	96.25
3	35.38	35.38	19.46	19.48	95.79
4	7.27	4.91	6.64	10.59	99.46
40	24.30	24.30	2.11	14.50	98.21
5	34.92	34.92	17.84	20.46	99.46
6	10.34	10.34	12.92	18.60	98.41
SS1A	-	-	-	-	-
SS1B	19.01	19.01	11.08	14.41	98.60
SS1C	8.67	8.67	5.20	9.88	99.39
SS2	-	-	-	-	-
SS3	-	-	-	-	-
SS4	7.28	0.62	1.73	5.67	99.84

Além dos resultados específicos de cada experimento, os autores puderam concluir que os modelos de PG e Redes Neurais apresentaram menor desvio em relação aos dados originais que outros modelos testados e que se adaptaram melhor à base de dados com diferentes características. Comparando especificamente os dois modelos baseados em PG e RN, o de PG mostrou-se um pouco melhor na maioria dos casos.

Tabela 3.2: Modelo Geométrico

<i>Base</i>	<i>md</i>	<i>pe</i>	<i>ab</i>	<i>ae</i>	<i>cc</i>
1	6.37	3.67	4.15	7.69	99.71
14C	-	-	-	-	-
17	27.08	27.08	-0.36	7.85	98.14
2	8.84	8.28	3.51	6.46	99.50
27	7.43	1.64	0.61	12.24	98.11
3	7.58	3.91	1.23	9.80	99.57
4	72.66	72.66	-1.62	14.55	95.56
40	68.31	56.30	-16.64	28.03	94.62
5	29.88	29.88	11.16	17.41	99.47
6	9.64	6.83	9.33	15.72	98.28
SS1A	-	-	-	-	-
SS1B	17.40	17.40	8.80	13.10	98.76
SS1C	1.40	0.81	3.07	9.41	99.56
SS2	-	-	-	-	-
SS3	-	-	-	-	-
SS4	6.59	0.49	1.63	5.44	99.84

Tabela 3.3: Modelo baseado em RN

<i>Base</i>	<i>md</i>	<i>pe</i>	<i>ab</i>	<i>ae</i>	<i>cc</i>
1	13.82	-4.88	6.77	7.15	99.29
14C	12.53	12.53	6.32	6.32	99.51
17	17.67	-12.48	-12.33	12.33	99.31
2	28.54	28.54	20.98	20.98	98.29
27	24.17	24.17	11.11	11.11	98.72
3	33.02	33.02	16.17	16.35	95.25
4	8.55	0.45	-2.30	3.54	99.61
40	12.20	4.79	7.36	7.36	99.47
5	22.15	-14.17	-13.73	13.87	99.21
6	19.68	19.68	10.88	10.88	98.74
SS1A	11.60	11.60	3.23	5.17	99.47
SS1B	21.91	21.91	12.04	12.04	98.61
SS1C	11.32	11.32	1.95	5.70	99.33
SS2	18.54	-18.54	7.49	7.52	99.34
SS3	8.21	8.21	3.41	3.62	99.80
SS4	23.63	23.63	12.54	12.54	98.46

3.3 Alguns Trabalhos de Seleção de Modelos de Confiabilidade

Alguns autores propuseram técnicas de seleção de um modelo de confiabilidade considerando o ciclo de desenvolvimento de software e *Aikake Information Criterion*, entre

Tabela 3.4: Modelo baseado em PG (Conjunto de Funções 1)

<i>Base</i>	<i>md</i>	<i>pe</i>	<i>ab</i>	<i>ae</i>	<i>cc</i>
1	-9.254	-25.268	-3.190	6.750	98.57
14C	170.210	170.210	360.840	356.410	12.60
17	12.728	9.340	2.270	9.680	98.24
2	11.556	4.818	2.274	4.084	99.60
27	56.320	54.210	19.240	17.660	85.22
3	80.240	82.410	15.610	17.450	66.32
4	-157.636	-157.642	-12.210	15.864	89.50
40	-116.056	-118.026	-27.838	38.818	90.44
5	9.790	9.234	-6.562	15.072	99.33
6	23.896	13.540	5.444	9.456	98.10
SS1A	5.334	5.302	-4.086	8.616	98.89
SS1B	18.436	18.436	3.118	9.798	98.87
SS1C	11.144	11.144	-1.640	10.462	97.22
SS2	14.176	11.272	-0.068	14.660	95.87
SS3	3.054	3.054	-0.040	14.772	96.57
SS4	6.184	4.684	-1.705	9.174	98.55

Tabela 3.5: Modelo baseado em PG (Conjunto de Funções 2)

<i>Base</i>	<i>md</i>	<i>pe</i>	<i>ab</i>	<i>ae</i>	<i>cc</i>
1	11.200	11.340	2.650	4.550	98.52
14C	-52.218	-52.218	-7.664	13.906	95.45
17	22.330	20.410	2.140	14.240	96.54
2	15.200	16.010	4.210	7.210	97.24
27	3.759	2.235	-1.612	14.066	96.75
3	3.966	3.966	-2.382	11.234	92.22
4	203.210	201.230	14.320	21.440	82.30
40	175.210	175.210	52.210	57.400	81.24
5	2.650	2.650	9.330	10.540	95.70
6	24.010	16.450	11.440	11.230	94.24
SS1A	35.440	39.210	9.880	12.320	97.66
SS1B	23.490	23.410	13.870	19.740	96.54
SS1C	9.340	9.150	17.660	16.650	97.20
SS2	12.670	4.440	11.740	12.060	94.05
SS3	27.120	28.470	11.960	11.080	96.30
SS4	17.990	13.970	10.880	27.850	97.99

outras. A seguir serão descritos brevemente o trabalho de Asad et al [6] e Khoshgof-taar et al [51]. No próximo capítulo é descrito a abordagem de seleção do modelo de confiabilidade proposta neste trabalho.

3.3.1 Seleção de Modelos Baseados na SDLC

Asad et al [6] apresentaram uma técnica de seleção de modelo de confiabilidade baseada no ciclo de desenvolvimento de software (SDLC), onde os modelos são selecionados de acordo com a pontuação atingida em uma determinada fase do desenvolvimento. A pontuação é calculada através da aplicabilidade de critérios pré-definidos sobre os modelos disponíveis para a fase do desenvolvimento.

Inicialmente, os modelos de confiabilidade são agrupados em seis categorias de acordo com suas características de predição e aplicação nas fases de desenvolvimento. As categorias são:

- *Early Prediction Models*
- *Software Reliability Growth Models*
- Modelos baseados em domínio de entrada
- Modelos baseados em arquitetura
- Modelos Híbridos de Caixa Preta
- Modelos Híbridos

A partir destas seis categorias, Asad et al [6] identificaram nove critérios que podem ajudar na seleção do modelo de confiabilidade durante as fases da SDLC (*Software Development Life Cycle*). Os critérios são

- Fase de Desenvolvimento
- Saída Esperada pelo Usuário
- Entrada Requerida pelo Modelo
- Tendência dos dados
- Verificação das Suposições do Modelo em relação aos dados
- Natureza do Projeto

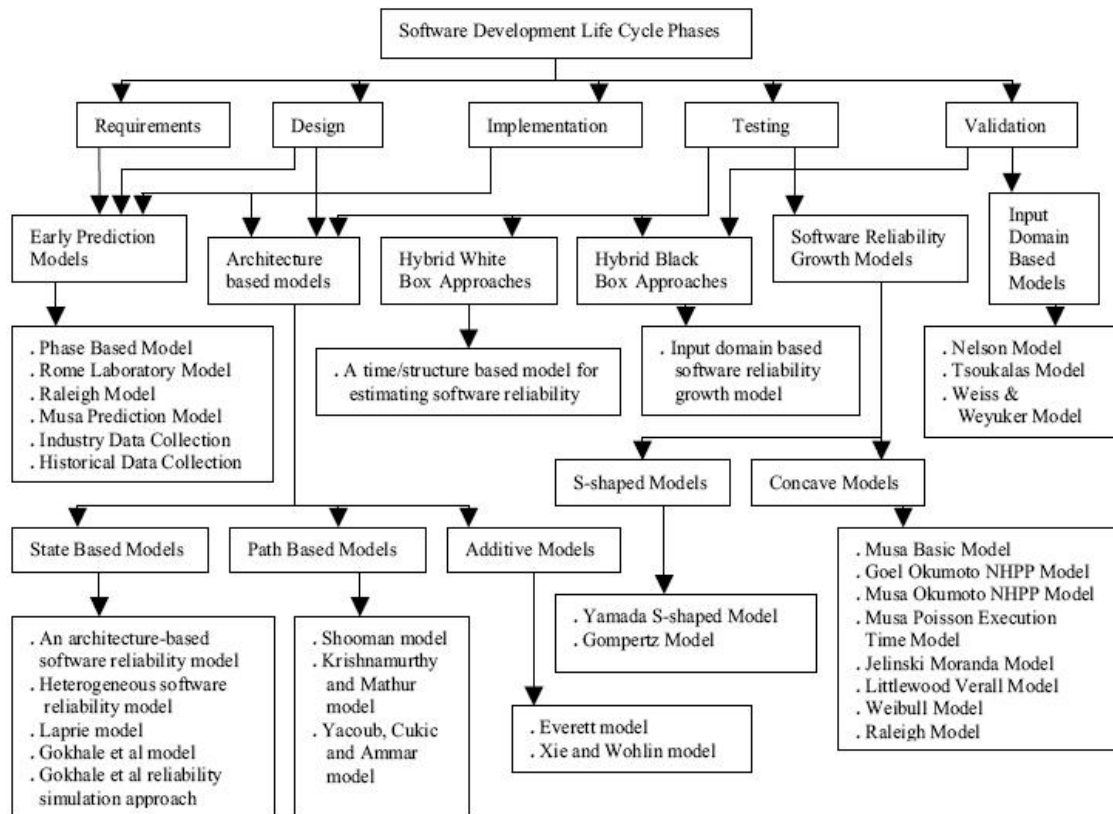


Figura 3.1: Distribuição dos Modelos de acordo com a Fase de Desenvolvimento

- Estrutura do Projeto
- Processo de Teste
- Processo de Desenvolvimento

A partir das classificações e critérios estabelecidos para trinta modelos de confiabilidade, os autores desenvolveram um algoritmo para pontuação dos modelos durante a fase de desenvolvimento do software e identificação de qual o modelo mais adequado para uma determinada etapa. As principais etapas do algoritmo são:

1. Seleção apenas dos modelos aplicados a fase de desenvolvimento através do critério “Fase de Desenvolvimento”.
2. Aplicação de um critério de seleção mais específica entre os critérios aplicáveis a uma determinada fase de desenvolvimento. Este critério buscar minimizar o número de candidatos.

3. Os candidatos restantes são submetidos aos demais critérios de seleção. Os critérios de seleção são acompanhados de pesos que indicam a sua importância naquela fase de desenvolvimento.
4. Ao final, os modelos foram pontuados de acordo com a sua aplicabilidade dentro da fase de desenvolvimento e o modelo mais bem pontuado é selecionado.

3.3.2 Seleção de Modelo baseado em *Aikake Information Criterion*

A existência de diversos modelos de confiabilidade e a constatação que nenhum deles apresentava bons resultados para quaisquer conjuntos de dados, incentivou uma mudança nos estudos de modelos de confiabilidade. Enquanto antes, muitos dos esforços nesta área estavam concentrados em propor novos modelos de confiabilidade, Khoshgoftaar e alguns autores passaram a propor formas de selecionar qual o modelo a ser utilizado dentre os diversos existentes.

Em [51], o autor analisa a aplicação da técnica denominada *Aikake Information Criteria* na seleção de um modelo de confiabilidade entre cinco modelos do tipo processos não homogêneos de Poisson. Para validar a técnica, Khoshgoftaar et al [51] utilizaram uma base com mais de 50.000 linhas de código de um projeto da IBM. Os modelos escolhidos para realização dos experimentos foram:

- Modelo de Goel e Okumoto
- Modelo S-Shaped
- Modelo *K-Stage Erlangian (Gamma) growth* com $K = 3$
- Modelo *K-Stage Erlangian (Gamma) growth* com $K = 4$
- Modelo Duane

Ao final do experimento, os autores constataram que o modelo S-Shaped apresentou os melhores resultados.

3.4 Considerações Finais

A estimativa de defeitos de software é uma característica importante no desenvolvimento de software. Uma estimativa precisa é fundamental na elaboração da estratégia de teste, na avaliação do grau de confiabilidade do software, na definição de quando a atividade de teste pode ser finalizada, na identificação de defeitos e de problemas no processo de desenvolvimento e impacto no custo do software.

No entanto, apesar da existência de diversos modelos para estimativa e cálculo da confiabilidade, nenhum deles consegue apresentar resultados precisos para todos e quaisquer conjuntos de dados, uma vez que as características do projeto influenciam na curva de crescimento da confiabilidade. Este fato motiva diversos estudos para definição de quais fatores influenciam no grau de adaptabilidade dos modelos aos conjuntos de dados. Modelos tradicionais, como o JAM e GEO tendem a apresentar bons resultados quando existe uma grande quantidade de dados, enquanto os modelos baseados em RN e PG são mais flexíveis e necessitam de menos dados, pois os ajustes dos parâmetros através de sucessivas iterações contribuem para modelos mais precisos.

Outros esforços também são realizados no sentido de informar parâmetros de ajustes aos modelos para tentar melhorar a precisão dos resultados. Modelos que recebem parâmetros são chamados de modelos paramétricos. Enquanto os modelos JAM e GEO são modelos paramétricos, os modelos baseados em PG e RN apesar de receberem parâmetros e funções para realização das predições, são ditos modelos não paramétricos visto que as características que definem o tipo da curva do modelo não precisam ser fornecidas. As curvas são realmente descobertas através dos dados.

Há algumas abordagens de escolha de qual modelo de confiabilidade a ser utilizado sobre uma base de dados. Devido a infinidade de variáveis e fatores que influenciam nos resultados de um modelo, analisar estas variáveis para cada modelo é uma tarefa custosa e difícil. Então, uma abordagem sugere a execução de vários modelos e selecionar aquele que apresenta os melhores resultados. Aparentemente este método pode parecer inviável, mas a implementação de ferramentas como CASRE, SMERFS, e SRMP [61] torna esta uma proposta atrativa. Outras técnicas também foram propostas para seleção de modelo

de confiabilidade, como nos trabalhos de Asad et al [6] e Khoshgoftaar et al [51]. No entanto, estes autores concentraram seus estudos fases específicas do desenvolvimento e não utilizaram nenhum modelo baseado em Aprendizado de Máquina.

O Aprendizado de Máquina tem sido utilizado para estabelecer modelos de confiabilidade de software, entretanto não na tarefa de seleção desses modelos. Para essa tarefa, este trabalho propõem o uso de Meta-Aprendizado que ainda não foi explorado na Engenharia de Software e na avaliação de confiabilidade. Sendo assim, no próximo capítulo é apresentada uma proposta de utilização de Meta-Aprendizado na seleção de qual modelo utilizar na avaliação da confiabilidade de software. A identificação de características comuns a várias bases de dados podem sugerir quais os melhores modelos a serem utilizados considerando dados empíricos.

CAPÍTULO 4

META-APRENDIZADO APLICADO À CONFIABILIDADE DE SOFTWARE

Como visto no capítulo anterior, existem inúmeros modelos de confiabilidade de software, entretanto, definir qual utilizar para um conjunto de dados específico depende de vários fatores, relacionados aos dados do conjunto e às premissas que os modelos consideram durante a avaliação da confiabilidade. Uma das formas de avaliá-los e definir qual modelo utilizar, é a execução de vários modelos sobre o mesmo conjunto de dados e verificar os resultados. No entanto, esta é uma abordagem muito custosa e que exige tempo. Este trabalho propõe que a seleção do melhor modelo para um conjunto seja feita através da aplicação de técnicas de Meta-Aprendizado, na qual algumas características observadas em base de dados históricas são analisadas e fornecem o conhecimento necessário para a indicação de um modelo de confiabilidade. Considerando isto, o problema está em identificar quais características dos dados influenciam na melhor adaptação de um modelo em comparação a outro e apresentar ao analista uma técnica para auxiliá-lo a selecionar qual modelo é mais adequado.

4.1 Visão Geral

A idéia proposta neste trabalho consiste na aplicação de técnicas de Aprendizado de Máquina sobre dados extraídos de conjuntos de dados relacionados à confiabilidade de software. Nesta abordagem, a seleção de um modelo de confiabilidade é uma tarefa de classificação onde as classes são os modelos. A Figura 4.1 representa o fluxograma da abordagem proposta.

Inicialmente, informações que representam as características dos dados da base são extraídos de bases relacionadas à confiabilidade de software (Meta-Dados), além da informação de qual foi o modelo de confiabilidade utilizado. Estes dados são submetidos

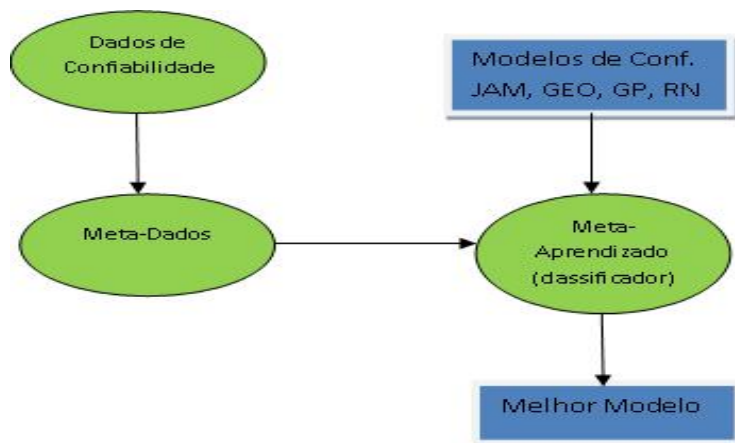


Figura 4.1: Visão Geral do Trabalho

a um algoritmo de Aprendizado de Máquina (Meta-Aprendizado) para indicação de qual o modelo a ser utilizado. O sucesso do Meta-Aprendizado está associado a escolha dos Meta-Dados corretos ao aprendizado.

Na próxima seção, descrevemos os experimentos realizados para a comprovação da idéia proposta aplicando duas técnicas diferentes de Aprendizado de Máquina baseadas em árvores de decisão e Redes Neurais para seleção de modelos de confiabilidade baseados no tempo.

4.2 Descrição dos Dados

Para realizar os experimentos que validam a aplicação de Meta-Aprendizado para indicação de um modelo de confiabilidade foram utilizados dados resultantes da aplicação dos modelos de confiabilidade JAM, GEO, PG e RN descritos no trabalho de Costa et al [25]. A partir das tabelas de resultado desses autores pode-se perceber que dependendo das bases, alguns modelos apresentaram melhores resultados do que outros tomando como parâmetro a medida de Erro Médio (*Average Error - ae*). O Erro Médio mede quão bem o modelo acerta as previsões durante a fase de teste. A fórmula de cálculo do Erro Médio é:

$$ae = \frac{1}{n} \sum_{i=1}^n \frac{||y_i - \hat{y}_i||}{y_i} \quad (4.1)$$

Onde:

- n é o número total de registros da base.
- y é o valor observado.
- \hat{y} é o valor estimado.

Das Tabelas 3.1, 3.2, 3.3 e 3.5 foi produzida a Tabela 4.1, indicando para cada base o valor para a medida ae obtido com cada modelo de confiabilidade (JAM, GEO, PG1, PG2 e RN). A hipótese assumida neste trabalho é que o melhor modelo de confiabilidade a ser aplicado em uma base de dados é aquele que apresentou o menor valor para a medida ae . Além disso, para cada registro desta tabela foram calculadas quatro variáveis estatísticas. Estas variáveis procuram apresentar características intrínsecas às bases que podem influenciar no resultado dos modelos de confiabilidade. São elas:

- Variância: representa o desvio quadrático médio da média de TBF's (*Time Between Failures*) normalizado, ou seja, representa o quão longe os valores da base estão do valor esperado (o valor médio). A normalização é feita através da divisão do TBF pelo valor médio de todos os TBF's da base. A normalização é necessária para que o modelo não seja dependente de características de unidade, ou mesmo do modo como as falhas foram identificadas. A fórmula da variância é:

$$\sigma^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{(n - 1)} \quad (4.2)$$

Onde:

- n é o número de registros no projeto.

- x_i é o TBF do registro i .
- \bar{x} é o valor médio do TBF.
- Inclinação: representa a inclinação da reta formada pelo TBF normalizado em relação ao tempo também normalizado. O tempo é normalizado através da divisão de todos os valores de tempos pelo maior valor, desta forma obtém-se a proporcionalidade do valor do tempo em relação à maior medida. A fórmula da inclinação da reta formada por dois pontos é:

$$b = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2} \quad (4.3)$$

Onde:

- n é o número total de registros no projeto.
- x_i é o TBF do registro i .
- y_i é a variável tempo do registro i .
- \bar{x} é o valor médio do TBF.
- \bar{y} é o valor médio da variável tempo.
- Auto-Correlação: representa quão distante um valor está de seu antecessor. Para realizar este cálculo, foram considerados os valores de TBF normalizados.

$$AC = \frac{\frac{1}{n} \sum_{i=2}^n (x_i - \bar{x})(y_i - \bar{y})}{\sigma_x * \sigma_y} \quad (4.4)$$

Onde:

- n é o número total de registros no projeto.

- x_i é o TBF do registro i .
- y_i é o TBF do registro $i-1$.
- \bar{x} é o valor médio do TBF.
- \bar{y} é o valor médio de TBF no momento anterior.
- σ_x é o desvio padrão do TBF.
- σ_y é o desvio padrão do TBF no momento anterior.

Onde n é o número de elementos da amostra, x é o valor de TBF no momento x , y é o valor de TBF em um momento de $x+1$ e μ é a média aritmética da variável.

- Ruído: representa o valor médio de ruído dos dados que descrevem a curva de identificação de falhas no transcorrer do tempo. Para cálculo do ruído é utilizado o conceito de médias móveis e é realizada uma normalização dos valores de TBF (*Time Between Failure*). A partir os TBF's normalizados, o ruído é calculado como a diferença entre o TBF normalizado e a média de TBF's normalizados ao quadrado considerando os cinco TBF's anteriores e próximos. A fórmula de cálculo do ruído pode ser resumida em:

$$R = \sqrt{\frac{\sum ((\sum_{i=i-5}^{i+5} \frac{TBF_i}{10}) - TBF_i)^2}{N}} \quad (4.5)$$

Onde N é o número de registros da base de dados.

4.3 Experimentos

A partir da Tabela 4.1 é possível traçar comparações entre os quatro modelos (JAM, GEO, PG2, RN), a fim de simular situações de decisão de qual o melhor modelo a aplicar em uma base considerando suas seguintes características: variância, inclinação, auto-correlação e ruído médio.

Tabela 4.1: Tabela de Meta-Dados

	Base	Variância	Inclinação	Auto-Correlação	Ruído Médio	<i>ae JAM</i>	<i>ae GEO</i>	<i>ae PG1</i>	<i>ae PG2</i>	<i>ae RN</i>
01	DS1	0.02879	0.35811	0.33067	0.13402	14.39	7.69	6.750	4.55	7.15
02	DS2	0.03944	0.45466	0.37182	0.1618	22.42	6.46	4.084	7.21	20.98
03	DS3	0.06978	0.69015	0.39584	0.16805	19.48	9.80	17.45	11.234	16.35
04	DS4	0.03793	0.70296	0.43633	0.05507	10.59	14.55	15.864	21.44	3.54
05	DS14C	0.06422	0.37030	0.09247	0.15079	—	—	356.41	13.906	6.32
06	DS5	0.01651	0.04997	0.13836	0.11496	20.46	17.41	15.072	10.54	13.87
07	DS6	0.02785	0.19466	0.00867	0.14702	18.60	15.72	9.456	11.23	10.88
08	DS17	0.03392	0.451	0.02008	0.07325	6.21	7.85	9.68	14.24	12.33
09	DS27	0.03109	0.56245	0.71428	0.06449	18.50	12.24	17.66	14.066	11.11
10	DS40	0.02924	0.2158	0.35269	0.1444	14.50	28.03	38.818	57.40	7.36
11	DSSS1A	0.05633	0.11014	0.12460	0.20658	—	—	8.616	12.32	5.17
12	DSSS1B	0.02611	0.01327	0.11879	0.14691	14.41	13.10	9.798	19.74	12.04
13	DSSS1C	0.02572	0.1018	0.18279	0.14227	9.88	9.41	10.462	16.65	5.70
14	DSSS2	0.03939	-0.03565	-0.00136	0.17727	—	—	14.660	12.06	7.52
15	DSSS3	0.02142	0.13134	0.11625	0.13551	—	—	14.772	11.08	3.62
16	DSSS4	0.03215	0.089	-0.03236	0.15702	5.67	5.44	9.174	27.85	12.54

Sendo assim, foram realizados doze experimentos que representam todas as combinações possíveis durante um processo de decisão de qual o melhor modelo para aplicação em uma dada base de dados, considerando a hipótese que o melhor modelo é aquele que apresenta o menor valor de erro médio. O modelo PG1 (Programação Genética com o conjunto de funções 1 do trabalho de Costa et al [25]) foi considerado apenas para comparação com o modelo PG2. Para a comparação com os demais modelos, o PG1 foi desconsiderado por apresentar resultados inferiores ao PG2 em relação ao Erro Médio.

1. JAM x GEO
2. JAM x RN
3. JAM x GEO x RN
4. JAM x GEO x PG2
5. JAM x RN x PG2
6. JAM x GEO x RN x PG2
7. JAM x PG2
8. PG1 x PG2
9. GEO x RN
10. GEO x PG2
11. GEO x RN x PG2
12. RN x PG2

4.3.1 Passos dos Experimentos

Em todos os doze experimentos, um mesmo conjunto de passos foi realizado e é descrito nesta seção. Para tornar o entendimento mais claro, utiliza-se o experimento de comparação entre os modelos JAM e GEO como exemplo. Os dados referentes aos outros experimentos estão nos apêndices de A a L.

4.3.1.1 Gerando a Tabela de Dados

À Tabela 4.1 e, para cada uma das doze comparações, foi adicionada a coluna *Modelo Ótimo* com o modelo que obteve o menor Erro Médio tomando como base o trabalho de Costa et al [25], gerando assim uma nova tabela que servirá como entrada de dados. A Tabela 4.2 é um exemplo de comparação entre os modelos JAM e GEO com a indicação de qual modelo obteve melhor resultado com relação ao Erro Médio (*ae*).

Tabela 4.2: Tabela JAM x GEO

	Base	Variância	Inclinação	Auto-Correlação	Ruído Médio	Modelo Ótimo	ae JAM	ae GEO
01	DS1	0.02879	0.35811	0.33067	0.13402	GEO	14.39	7.69
02	DS2	0.03944	0.45466	0.37182	0.1618	GEO	22.42	6.46
03	DS3	0.06978	0.69015	0.39584	0.16805	GEO	19.48	9.80
04	DS4	0.03793	0.70296	0.43633	0.05507	JAM	10.59	14.55
06	DS5	0.01651	0.04997	0.13836	0.11496	GEO	20.46	17.41
07	DS6	0.02785	0.19466	0.00867	0.14702	GEO	18.60	15.72
08	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	7.85
09	DS27	0.03109	0.56245	0.71428	0.06449	GEO	18.50	12.24
10	DS40	0.02924	0.2158	0.35269	0.1444	JAM	14.50	28.03
12	DSSS1B	0.02611	0.01327	0.11879	0.14691	GEO	14.41	13.10
13	DSSS1C	0.02572	0.1018	0.18279	0.14227	GEO	9.88	9.41
16	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.67	5.44

Quando é feita a comparação entre modelos dos quais para pelo menos um não pôde ser calculado o Erro Médio, então este registro é descartado para não distorcer o resultado do experimento. O valor de Erro Médio não pôde ser calculado quando o modelo não conseguiu extrair conhecimento/padrão nos dados da base de treinamento. Esta situação ocorre sempre que uma comparação envolve os métodos JAM ou GEO, então os registros das bases DS14C, DSSS1A, DSSS2 e DSSS3 são descartados nestes experimentos.

4.3.1.2 Gerando Registros Sintéticos

Uma das maiores dificuldades dos pesquisadores na realização de trabalhos que necessitam de dados históricos é a obtenção de dados para realização de experimentos. A aplicação de

técnicas de Aprendizado de Máquina apresenta resultados mais precisos quando o conjunto de dados apresenta um número razoável de representantes de cada classe do aprendizado. Para contornar esta dificuldade, existem algumas técnicas de replicação/criação de dados que permitem aos algoritmos de descoberta de conhecimento identificar padrões e características dos dados com mais facilidade. Estas técnicas não distorcem o conhecimento já inserido nas bases originais, apenas o destaca nas bases com dados replicados [17, 18].

Neste trabalho, a abordagem adotada foi a geração de registros sintéticos a partir de dados do trabalho de Costa et al [25]. O principal objetivo da geração dos registros sintéticos é a composição de uma base com um número equilibrado de elementos de todos os modelos que estão sendo comparados. O equilíbrio do número de exemplares de todas as classes em uma base de aprendizado evita que classes com mais exemplos tenham maior influência ou que classes com menos exemplares não tenham pesos semelhantes na aplicação dos algoritmos de Aprendizado de Máquina. Neste trabalho foi utilizada a abordagem de replicação descrita em [17].

A criação dos exemplos sintéticos seguiu os critérios de vizinho mais próximo implementados no algoritmo KNN (*K Nearest Neighbor*) [68]. O KNN é um algoritmo de classificação que seleciona os K vizinhos mais próximos do ponto indicado e o classifica de acordo com a classe mais numerosa pertencente aos K vizinhos selecionados. A identificação de quais são os vizinhos mais próximos é feita através do cálculo da distância euclidiana entre os pontos. A fórmula de cálculo da distância euclidiana entre dois pontos $A(X1, Y1)$ e $B(X2, Y2)$ é:

$$distancia = \sqrt{((X1 - X2)^2) + ((Y1 - Y2)^2)} \quad (4.6)$$

O algoritmo de replicação produz uma base com trinta e um registros, dos quais trinta são utilizados como base de treinamento e um como base de validação. O número trinta foi escolhido por considerar que este número de registros é suficiente para que o algoritmo de Aprendizado de Máquina identifique as regras e padrões dos registros. A base final

para aplicação do algoritmo é composta dos registros originais mais os exemplos sintéticos gerados pelo algoritmo de geração de registros.

No algoritmo desenvolvido para geração dos exemplos, a distância entre os pontos é calculada considerando as variáveis estatísticas Variância, Inclinação, Auto-Correlação e Ruído Médio.

A base final para realização do Aprendizado de Máquina foi obtida através dos seguintes passos:

1. Leitura dos registros da base de dados original, tal como a tabela 4.2 .
2. Identificação da classe que possui mais representantes.
3. Geração de exemplos para as demais classes de forma a compor uma base com igual número de representantes para todas as classes.
4. Após a equalização do número de representantes de todas as classes da base, se o número total de registros for menor que 31 então o número faltante para completar os 31 registros é dividido entre as diferentes classes da base e novos exemplos são gerados para cada base.

Neste algoritmo, o ponto chave é a geração de exemplos. Esta função tem os seguintes procedimentos:

1. A função recebe a indicação de qual classe de registros o exemplo deve pertencer.
2. Seleciona aleatoriamente um registro da base que possua a mesma classe do exemplo a ser gerado. O registro selecionado pode ser um registro da base original ou um exemplo sintético gerado pelo próprio algoritmo.
3. Tendo selecionado um registro, identifica qual o vizinho mais próximo de mesma classe através do cálculo da distância euclidiana. No caso de classes que só possuem um representante, então seleciona o vizinho mais próximo independentemente da classe.

4. Calcula o valor médio da variância, inclinação, auto-correlação e ruído médio entre os pontos seleccionados. Estes valores médios compõem um novo ponto.
5. Para casos onde foi possível encontrar um vizinho de mesma classe, é calculado novamente o valor médio da variância, inclinação, auto-correlação e ruído médio entre o primeiro ponto e o ponto médio e então é gerado um novo registro sintético na base. O mesmo ocorre no cálculo do valor médio entre o ponto médio e o segundo ponto. Sendo assim, para cada execução do gerador de registros, dois novos registros são criados de uma mesma classe, como na Figura 4.2.




Figura 4.2: Caso 1 - Geração de dois registros sintéticos

No caso dos pontos seleccionados serem de classes distintas, apenas um ponto é gerado. O ponto gerado é resultante do cálculo dos valores médios entre o primeiro ponto e o ponto médio, como na Figura 4.3.




Figura 4.3: Caso 2 - Geração de um registro sintético

6. Armazena os dados do exemplo gerado na base de dados.

Ao final deste passo é gerada uma tabela com 31 registros contendo os registros originais e sintéticos. Nesse capítulo somente a tabela de comparação dos modelos JAM e GEO é apresentada, conforme Tabela 4.3. As demais tabelas referentes aos outros experimentos estão nos apêndices.

Tabela 4.3: Tabela JAM x GEO SINTÉTICOS

Num. Registro	Base	Variação	Inclinação	Auto- Correlação	Ruído Médio	Classe	ae ÓTIMO	ae JAM	ae GEO
1	DS1	0.02879	0.35811	0.33067	0.13402	GEO	7.69	14.39	7.69
2	DS2	0.03944	0.45466	0.37182	0.1618	GEO	6.46	22.42	6.46
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	19.48	9.8
4	DS4	0.03793	0.70296	0.43633	0.05507	JAM	10.59	10.59	14.55
5	DS5	0.01651	0.04997	0.13836	0.11496	GEO	17.41	20.45999	17.41
6	DS6	0.02785	0.19466	0.00867	0.14702	GEO	15.72	18.6	15.72
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	7.85
8	DS27	0.03109	0.56245	0.71428	0.06449	GEO	12.24	18.5	12.24
9	DS40	0.02924	0.2158	0.35269	0.1444	JAM	14.5	14.5	28.03001
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	GEO	13.1	14.41	13.1
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	GEO	9.41	9.88	9.41
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.67	5.44
13	SINT-7-9	0.03275	0.3922	0.103233	0.091037	JAM	8.282499	8.282499	12.895
14	SINT-7-9	0.03041	0.2746	0.269538	0.126612	JAM	12.4275	12.4275	22.985001
15	SINT-4-14	0.03605	0.59587	0.394632	0.072956	JAM	11.049376	11.049376	16.658751
16	SINT-4-14	0.03229	0.38169	0.311236	0.108727	JAM	11.968124	11.968124	20.876251
17	SINT-15-16	0.03511	0.542325	0.373783	0.081898	JAM	11.279062	11.279062	17.713127
18	SINT-15-16	0.03323	0.435235	0.332085	0.099784	JAM	11.738438	11.738438	19.821877
19	SINT-17-18	0.03464	0.515553	0.363358	0.08637	JAM	11.393906	11.393906	18.240314
20	SINT-17-18	0.0337	0.462008	0.342509	0.095313	JAM	11.623594	11.623594	19.294689
21	SINT-15-20	0.035462	0.562404	0.381601	0.078545	JAM	11.19293	11.19293	17.317734
22	SINT-15-20	0.034287	0.495473	0.35554	0.089723	JAM	11.48004	11.48004	18.635704
23	SINT-16-22	0.032789	0.410136	0.322312	0.103976	JAM	11.846104	11.846104	20.316114
24	SINT-16-22	0.033788	0.467027	0.344464	0.094474	JAM	11.60206	11.60206	19.195841
25	SINT-19-24	0.034427	0.503421	0.358635	0.088396	JAM	11.445944	11.445944	18.479197
26	SINT-19-24	0.034001	0.479159	0.349187	0.092448	JAM	11.550022	11.550022	18.956959
27	SINT-2-12	0.037617	0.363245	0.270775	0.160605	GEO	6.205	18.2325	6.205
28	SINT-2-12	0.033973	0.180415	0.068685	0.158215	GEO	5.695	9.8575	5.695
29	SINT-3-28	0.060828	0.562716	0.314051	0.165591	GEO	8.77375	17.074375	8.77375
30	SINT-3-28	0.042924	0.307849	0.150474	0.160674	GEO	6.72125	12.263124	6.72125
31	SINT-8-30	0.034049	0.4988	0.573328	0.088536	GEO	10.860312	16.940781	10.860312

4.3.1.3 Indicando o Melhor Modelo

Uma vez gerada a base com os trinta e um exemplos, sendo alguns reais e outros sintéticos, é iniciado o processo de validação cruzada sobre esta base. Cada registro desta base é removido para compor uma base de validação e o restante dos trinta registros compõem a base de treinamento. Este processo é realizado para todos os trinta e um registros. Desta forma, ao final há 31 bases de treinamento e 31 bases de validação. O método de separar um elemento do conjunto de dados, realizar o aprendizado sobre a base de treinamento e depois utilizar o elemento separadamente para validar a tarefa aprendida é chamado de *Leave-one-out cross validation* [52, 68].

Estas bases de treinamento foram submetidas aos algoritmos J48, algoritmo este baseado no C4.5 [82], e *MultilayerPerceptron*, algoritmo de redes neurais, do aplicativo Weka [102] para realização do Aprendizado de Máquina sobre os meta-dados (Meta-Aprendizado). Então, o Weka produziu como resultado árvores de decisão e redes neurais, respectivamente, que indicam qual o melhor modelo considerando os valores das variáveis: variância, inclinação, auto-correlação e ruído.

O resultado do algoritmo J48 para as bases de treinamento são árvores de decisão, conforme alguns exemplos apresentados nas Figuras 4.4, 4.5 e 4.6. As árvores são geradas considerando como atributo “classe” da tabela o campo *Classe* (Tabela 4.3), ou seja, o modelo considerado como ótimo para o registro.

Ao final da aplicação do algoritmo J48 para as trinta e uma bases de treinamento, as árvores de decisão são confrontadas contra os registros de validação. O modelo indicado pela árvore de decisão é apresentado adicionando-se duas colunas à Tabela 4.3, coluna “Classe Árvore” e coluna “AE Árvore”. A coluna “AE Árvore” contém o valor de erro médio associado ao modelo indicado pela árvore de decisão. Estes dados estão na Tabela 4.4.

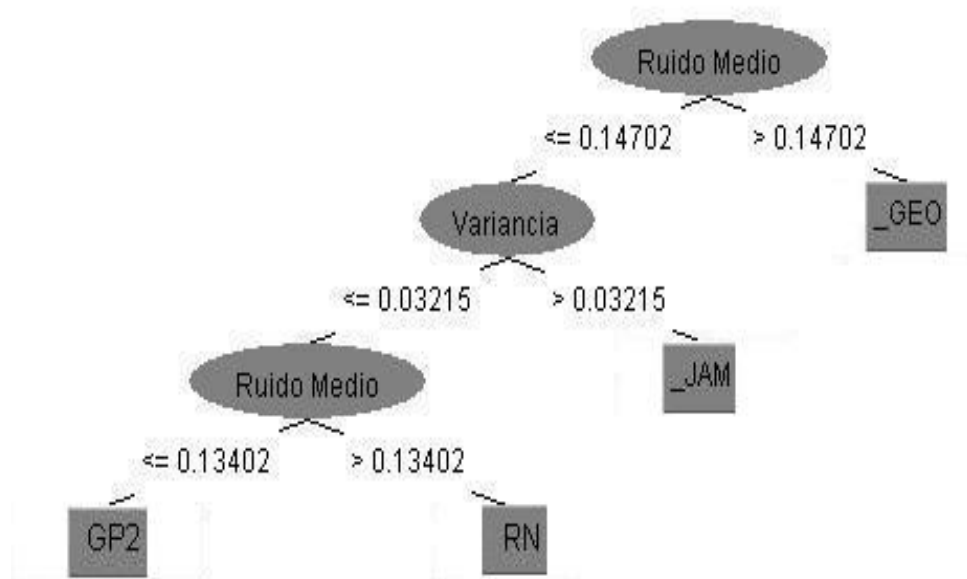


Figura 4.4: Árvore de Decisão (JAM x GEO x PG2 x RN)

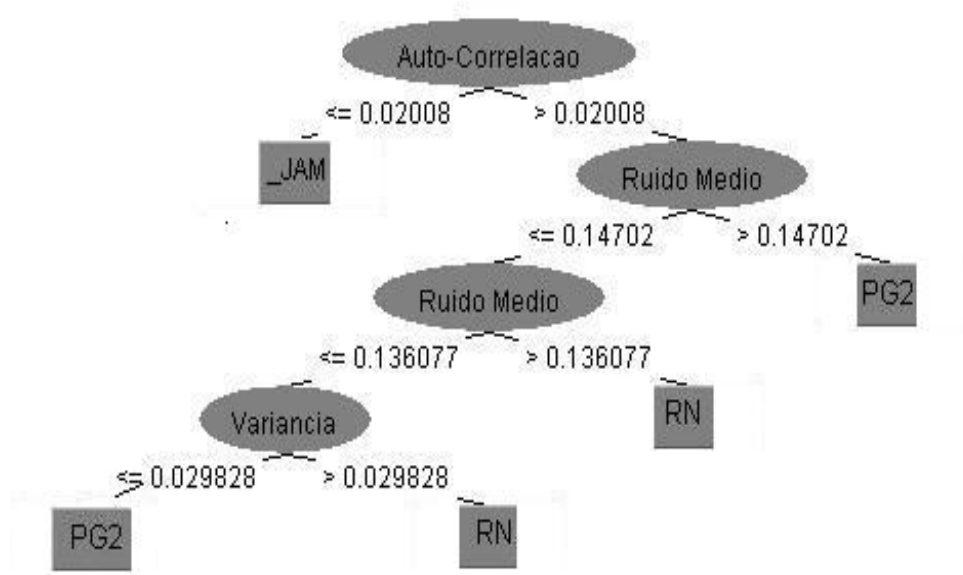


Figura 4.5: Árvore de Decisão (JAM x PG2 x RN)

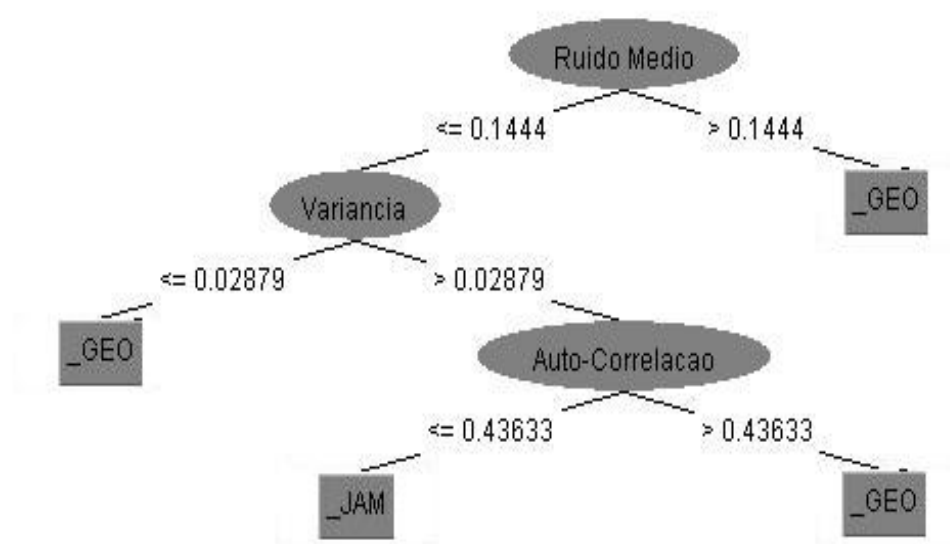


Figura 4.6: Árvore de Decisão (JAM x GEO)

Tabela 4.4: Tabela JAM x GEO - Modelos Indicados pelas Árvores e Redes Neurais

Num. Registro	Base	Variação	Inclinação	Correlação	Auto	Ruído	Classe	AE ÓTIMO	AE JAM	AE GEO	Classe Árvore	AE Árvore	Classe Rede Neural	AE Rede Neural	AE
1	DS1	0.02879	0.35811	0.33067	0.33067	0.13402	GEO	7.69	14.39	7.69	JAM	14.39	JAM	14.39	14.39
2	DS2	0.03944	0.45466	0.37182	0.37182	0.1618	GEO	6.46	22.42	6.46	GEO	6.46	GEO	6.46	6.46
3	DS3	0.06978	0.69015	0.39584	0.39584	0.16805	GEO	9.8	19.48	9.8	GEO	9.8	GEO	9.8	9.8
4	DS4	0.03793	0.70296	0.43633	0.43633	0.05507	JAM	10.59	10.59	14.55	GEO	14.55	JAM	10.59	10.59
5	DS5	0.01651	0.04997	0.13836	0.13836	0.11496	GEO	17.41	20.459999	17.41	JAM	20.459999	JAM	20.459999	20.459999
6	DS6	0.02785	0.19466	0.00867	0.00867	0.14702	GEO	15.72	18.6	15.72	GEO	15.72	GEO	15.72	15.72
7	DS17	0.03392	0.451	0.02008	0.02008	0.07325	JAM	6.21	6.21	7.85	JAM	6.21	JAM	6.21	6.21
8	DS27	0.03109	0.56245	0.71428	0.71428	0.06449	GEO	12.24	18.5	12.24	JAM	18.5	JAM	18.5	18.5
9	DS40	0.02924	0.2158	0.35269	0.35269	0.1444	JAM	14.5	14.5	28.030001	GEO	28.030001	GEO	28.030001	28.030001
10	DSSS1B	0.02611	0.01327	0.11879	0.11879	0.14691	GEO	13.1	14.41	13.1	GEO	13.1	GEO	13.1	13.1
11	DSSS1C	0.02572	0.1018	0.18279	0.18279	0.14227	GEO	9.41	9.88	9.41	GEO	9.41	GEO	9.41	9.41
12	DSSS4	0.03215	0.089	-0.03236	0.03236	0.15702	GEO	5.44	5.67	5.44	GEO	5.44	GEO	5.44	5.44
13	SINT-7-9	0.03275	0.3922	0.103233	0.103233	0.091037	JAM	8.282499	8.282499	12.895	JAM	8.282499	JAM	8.282499	8.282499
14	SINT-7-9	0.03041	0.2746	0.269538	0.269538	0.126612	JAM	12.4275	12.4275	22.985001	GEO	22.985001	GEO	22.985001	22.985001
15	SINT-4-14	0.03605	0.59587	0.394632	0.394632	0.072956	JAM	11.049376	11.049376	16.658751	JAM	11.049376	JAM	11.049376	11.049376
16	SINT-4-14	0.03229	0.38169	0.311236	0.311236	0.108727	JAM	11.968124	11.968124	20.876251	JAM	11.968124	JAM	11.968124	11.968124
17	SINT-15-16	0.03511	0.542325	0.373783	0.373783	0.081898	JAM	11.279062	11.279062	17.713127	JAM	11.279062	JAM	11.279062	11.279062
18	SINT-15-16	0.03323	0.435235	0.332085	0.332085	0.099784	JAM	11.738438	11.738438	19.821877	JAM	11.738438	JAM	11.738438	11.738438
19	SINT-17-18	0.03464	0.515553	0.363358	0.363358	0.08637	JAM	11.393906	11.393906	18.240314	JAM	11.393906	JAM	11.393906	11.393906
20	SINT-17-18	0.0337	0.462008	0.342509	0.342509	0.095313	JAM	11.623594	11.623594	19.294689	JAM	11.623594	JAM	11.623594	11.623594
21	SINT-15-20	0.035462	0.562404	0.381601	0.381601	0.078545	JAM	11.19293	11.19293	17.317734	JAM	11.19293	JAM	11.19293	11.19293
22	SINT-15-20	0.034287	0.495473	0.35554	0.35554	0.089723	JAM	11.48004	11.48004	18.635704	JAM	11.48004	JAM	11.48004	11.48004
23	SINT-16-22	0.032789	0.410136	0.322312	0.322312	0.103976	JAM	11.846104	11.846104	20.316114	JAM	11.846104	JAM	11.846104	11.846104
24	SINT-16-22	0.033788	0.467027	0.344464	0.344464	0.094474	JAM	11.60206	11.60206	19.195841	JAM	11.60206	JAM	11.60206	11.60206
25	SINT-19-24	0.034427	0.503421	0.358635	0.358635	0.088396	JAM	11.445944	11.445944	18.479197	JAM	11.445944	JAM	11.445944	11.445944
26	SINT-19-24	0.034001	0.479159	0.349187	0.349187	0.092448	JAM	11.550022	11.550022	18.956959	JAM	11.550022	JAM	11.550022	11.550022
27	SINT-2-12	0.037617	0.363245	0.270775	0.270775	0.160605	GEO	6.205	18.2325	6.205	GEO	6.205	GEO	6.205	6.205
28	SINT-2-12	0.033973	0.180415	0.068685	0.068685	0.158215	GEO	5.695	9.8575	5.695	GEO	5.695	GEO	5.695	5.695
29	SINT-3-28	0.060828	0.562716	0.314051	0.314051	0.165591	GEO	8.77375	17.074375	8.77375	GEO	8.77375	GEO	8.77375	8.77375
30	SINT-3-28	0.042924	0.307849	0.150474	0.150474	0.160674	GEO	6.72125	12.263124	6.72125	GEO	6.72125	GEO	6.72125	6.72125
31	SINT-8-30	0.034049	0.4988	0.573328	0.573328	0.088536	GEO	10.860312	16.940781	10.860312	JAM	16.940781	JAM	16.940781	16.940781

O mesmo procedimento é feito para o resultado gerado pelo algoritmo *MultilayerPerceptron*. As redes neurais são geradas a partir das mesmas bases de treinamento utilizadas para gerar as árvores de decisão e o teste é realizado sobre cada um dos 31 registros. O resultado da indicação da rede neural também é apresentado nas duas últimas colunas da Tabela 4.4, coluna “Classe Rede Neural” e coluna “AE Rede Neural”(Tabela 4.4).

4.3.1.4 Preparação das Tabelas de Resultados para Análise

À Tabela 4.4 foram adicionadas duas outras colunas. Uma dessas colunas, denominada “Modelo Aleatório” contém um modelo selecionado aleatoriamente dentre os modelos que fazem parte do experimento. Esta seleção aleatória ocorre para cada um dos 31 registros da tabela, e simula a situação do analista que está avaliando a confiabilidade do software indicar modelo sem critério algum. A outra coluna contém o valor de Erro Médio (*AE*) associado ao modelo selecionado aleatoriamente. Esta coluna é chamada de “AE Modelo Aleat.”. Ao final deste procedimento, a tabela final para análise é composta das seguintes colunas, como a Tabela A.1 do apêndice:

- Num.Registro: contador de 1 a 31 indicando o número do registro.
- Base: nome da base de dados que formou o registro. Para os registros gerados, o nome é indicado por ”SINT-” mais a concatenação do número do registro das bases que foram utilizadas para gerar o registro.
- Variância: valor da variância do registro, para registros sintéticos é o valor calculado conforme processo descrito na Seção 4.2 deste capítulo.
- Inclinação: valor da inclinação do registro, para registros sintéticos é o valor calculado conforme processo descrito na Seção 4.2 deste capítulo.
- Auto-Correlação: valor de auto-correlação do registro, para registros sintéticos é o valor calculado conforme processo descrito na Seção 4.2 deste capítulo.
- Ruído Médio: valor de ruído médio do registro, para registros sintéticos é o valor calculado conforme processo descrito na Seção 4.2 deste capítulo.

- Classe: é nome do modelo que apresentou o menor erro médio dentre os modelos em comparação.
- AE ÓTIMO: é o valor do Erro Médio do modelo indicado na coluna “Classe”.
- Duas ou mais dentre as colunas abaixo conforme os modelos que estão sendo comparados:
 - AE JAM: é o valor do Erro Médio do modelo JAM para o registro.
 - AE GEO: é o valor do Erro Médio do modelo GEO para o registro.
 - AE PG1: é o valor do Erro Médio do modelo PG1 para o registro.
 - AE PG2: é o valor do Erro Médio do modelo PG2 para o registro.
 - AE RN: é o valor do Erro Médio do modelo RN para o registro.
- Classe Árvore: é o modelo indicado pela árvore de decisão gerada pelo Meta Aprendizado para o registro.
- AE Árvore: é o valor do Erro Médio do modelo indicado pela coluna “Classe Árvore” para o registro.
- Classe Rede Neural: é o modelo indicado pela rede neural gerada pelo Meta Aprendizado para o registro.
- AE Rede Neural: é o valor do Erro Médio do modelo indicado pela coluna “Classe Rede Neural” para o registro.
- Modelo Aleatório: é um modelo, dentre os modelos em comparação no experimento, selecionado aleatoriamente. Por exemplo, no experimento de comparação entre JAM, GEO, PG2 e RN, para cada registro da base é selecionado um desses quatro modelos aleatoriamente, simulando uma escolha de modelo sem critério.
- AE Modelo Aleat.: é o valor do Erro Médio do modelo indicado pela coluna “Modelo Aleatório” para o registro.

Após a adição das colunas com a indicação de um modelo dentre os pertencentes ao experimento, selecionado aleatoriamente, há a necessidade de realização do mesmo experimento por mais algumas vezes para evitar resultados casuais. Sendo assim, os 31 registros originais foram replicados dez vezes e a coluna com o modelo aleatório e seu respectivo Erro Médio (AE) foi recalculado, compondo uma base final com 310 registros.

Para finalizar a preparação dos resultados para a análise é necessário realizar a padronização dos valores de Erro Médio. Este procedimento é necessário para remover eventuais diferenças quanto a forma de captação dos valores, uma vez que os registros das bases foram compostos por projetos de diferentes assuntos. Com a normalização dos valores entre 0 e 1 todas as medidas de Erro Médio são calculadas em termo do maior erro entre os quatro modelos. As tabelas finais e padronizadas que servirão para análise dos resultados estão nos apêndices de A a L.

Uma vez realizada a preparação das tabelas para análise dos resultados, as colunas com o Erro Médio (AE) dos modelos comparados são totalizadas. A partir desta totalização é possível traçar um comparativo entre o Erro Médio Ótimo, dos modelos comparados, do modelo indicado pela árvore, o modelo indicado pela rede neural e do modelo selecionado aleatoriamente.

Além da totalização dos valores de erros médios, é aplicado o teste estatístico **Teste t** [79] para comparação dos Erros Médios do Modelo Ótimo, Aleatório e dos Modelos Comparados contra o Erro Médio produzido pela Árvore de Decisão e contra o Erro Médio resultante da Rede Neural. Esta mesma comparação é realizada também com os valores padronizados.

O Teste t foi publicado em 1908 pelo estatístico William Sealy Gosset para testar a qualidade das cervejas produzidas. Mais conhecido como Testes t *Student*, o teste busca verificar a hipótese inicial, chamada de hipótese nula, de a média de duas distribuições normais serem iguais, contra a hipótese alternativa da distinção da média das duas distribuições [79]. Há diversas versões de Teste t sendo que os testes mais comuns ocorrem quando dois exemplos são:

- Independentes: os indivíduos são inseridos aleatoriamente em dois grupos.

- Pareado: há um mapeamento de um para um entre os elementos dos grupos onde está sendo aplicado o Teste t. Este é o tipo de teste adotado neste trabalho.

A aplicação do Teste t produz como resultado o p-valor. O p-valor é a medida de quanta evidência se tem contra a hipótese nula, ou seja, mede a probabilidade de se obter dados tão ou mais extremos que os observados, assumindo que a hipótese nula é verdadeira. Portanto, quanto menor o p-valor, mais evidência se tem contra a hipótese nula. A análise do resultado da aplicação diz que, se o p-valor for menor que a significância estatística escolhida (normalmente 5%) então a hipótese nula do teste de que os dois grupos não diferem é rejeitada, e a hipótese complementar, ou seja, que os grupos são diferentes é aceita. Neste trabalho adota-se a significância estatística de 5%.

4.4 Análise dos Resultados

As análises são realizadas sobre os dados padronizados para evitar que dados captados em unidades diferentes influenciem nos resultados. Das tabelas resultantes dos doze experimentos foram produzidas as Tabelas 4.5 e 4.6 de avaliação de resultados.

Tabela 4.5: Tabela Soma Erro Médio (Padronizado)

Experimentos	AE JAM	AE GEO	AE PG1	AE PG2	AE RN	AE Aleat.	AE Ótimo	AE Árvore	AE Rede Neural
JAM x GEO	245.90	261.25				256.65	197.16	222.42	219.70
JAM x RN	225.52				258.44	249.54	173.96	183.07	179.71
JAM x GEO x RN	226.64	194.47			270.14	235.55	156.68	168.31	176.27
JAM x GEO x PG2	206.33	179.83		243.51		213.86	132.58	163.10	162.32
JAM x RN x PG2	176.31			266.55	165.20	199.75	109.68	133.38	137.37
JAM x GEO x RN x PG2	220.12	166.05		245.84	207.17	217.24	122.14	140.41	138.29
JAM x PG2	226.23			248.62		239.06	164.85	201.36	200.13
PG1 x PG2			232.15	233.11		231.20	155.26	204.70	172.69
GEO x RN		215.86			263.95	245.62	169.81	178.30	172.89
GEO x PG2		229.69		261.34		241.42	181.03	195.61	181.03
GEO x RN x PG2		203.95		263.79	209.75	230.37	147.17	153.11	166.21
RN x PG2				246.88	232.67	231.12	169.55	206.86	192.46

A Tabela 4.5 contém um linha para cada experimento realizado. Em cada uma das linhas é computado o valor resultante da soma dos Erros Médios padronizados referentes a todos os registros da tabela de dados do experimento. Além da tabela 4.5, cada experimento também é representado em gráficos das figuras 4.7, 4.8, 4.9, 4.10, 4.11, 4.12 que apresentam os valores de Erro Médio e traçam uma comparação entre as medidas de obtidas de erro médio em cada experimento.




Figura 4.7: Experimentos **JAM x GEO** e **JAM x RN**




Figura 4.8: Experimentos **JAM x GEO x RN** e **JAM x GEO x PG2**




Figura 4.9: Experimentos **JAM x RN x PG2** e **JAM x GEO x RN x PG2**




Figura 4.10: Experimentos **JAM x PG2** e **PG1 x PG2**




Figura 4.11: Experimentos **GEO x RN** e **GEO x PG2**




Figura 4.12: Experimentos **GEO x RN x PG2** e **RN x PG2**

Tabela 4.6: Comparativo Erro Médio Ótimo x Erro Médio Modelos (% de casos onde o método escolhido é igual ao Mét. Ótimo)

Experimentos	JAM	% JAM	GEO	% GEO	PG1	% PG1	PG2	% PG2	RN	% RN	Modelo Aleat.	% Aleat.	Modelo Árvore	% Árvore	Mod. Rede Neural	% Rede Neural
JAM x GEO	170.00	54.84	140.00	45.16							146.00	47.10	240.00	77.42	250.00	80.65
JAM x RN	160.00	51.61							150.00	48.39	145.00	46.77	290.00	93.55	290.00	93.55
JAM x GEO x RN	120.00	38.71	110.00	35.48					80.00	25.81	100.00	32.26	270.00	87.10	270.00	87.10
JAM x GEO x PG2	110.00	35.48	100.00	32.26			100.00	32.26			113.00	36.45	230.00	74.19	240.00	77.42
JAM x RN x PG2	120.00	38.71					70.00	22.58	120.00	38.71	114.00	36.77	240.00	77.42	240.00	77.42
JAM x GEO x RN x PG2	80.00	25.81	90.00	29.03			60.00	19.35	80.00	25.81	64.00	20.65	260.00	83.87	270.00	87.10
JAM x PG2	160.00	51.61					150.00	48.39			149.00	48.06	240.00	77.42	240.00	77.42
PG1 x PG2					170.00	54.84	140.00	45.16			158.00	50.97	170.00	54.84	240.00	77.42
GEO x RN			160.00	51.61					150.00	48.39	146.00	47.10	290.00	93.55	300.00	96.77
GEO x PG2			170.00	54.84			140.00	45.16			162.00	52.26	270.00	87.10	310.00	100.00
GEO x RN x PG2			120.00	38.71			70.00	22.58	120.00	38.71	96.00	30.97	290.00	93.55	270.00	87.10
RN x PG2							150.00	48.39	160.00	51.61	167.00	53.87	240.00	77.42	260.00	83.87
% Médio de "Acerto "												41.94		81.45		85.48




Figura 4.13: Comparativo do Erro Médio Ótimo x Erro Médio dos Modelos

Já a Tabela 4.6 apresenta o percentual, para cada experimento, de casos que o modelo indicado pela coluna nominada pelo modelos de confiabilidade é igual ao modelo ótimo. Além do cálculo para os modelos JAM, GEO, PG1, PG2 e RN, a Tabela 4.6 apresenta os percentuais de acerto para os casos de utilizar modelos escolhidos aleatoriamente, modelos indicados pelo Meta-Aprendizado com Árvore de Decisão e o Meta-Aprendizado com Redes Neurais. No final da tabela, é calculado o percentual médio de “Acerto” com relação ao modelo ótimo. Esta mesma tabela é representado pelo gráfico da figura 4.13.

Das tabelas resultantes dos doze experimentos de comparação entre os modelos de confiabilidade podem ser feitas as seguintes análises:

- Análise do Meta-Aprendizado utilizando Árvore de Decisão
- Análise do Meta-Aprendizado utilizando Redes Neurais
- Comparação entre o resultado de Árvore de Decisão e Redes Neurais

4.4.1 Análise dos Resultados das Árvore de Decisão

Dos doze experimentos, além das Tabelas 4.5 e 4.6, considerando o modelo indicado pelo Meta-Aprendizado com árvore de decisão foram produzidas as Tabelas 4.7 e 4.8 com os resultados da aplicação do Teste t.

Tabela 4.7: Tabela de Test t - Erro Médio da Árvore x Dados Não-Normalizados

Experimentos	JAM	GEO	PG1	PG2	RN	OTIMO	ALEAT.
JAM x GEO	0.001	0.000				0.000	0.000
JAM x RN	0.000				0.000	0.000	0.000
JAM x GEO x RN	0.000	0.000			0.000	0.000	0.000
JAM x GEO x PG2	0.000	0.000		0.000		0.000	0.000
JAM x RN x PG2	0.000			0.000	0.000	0.000	0.000
JAM x GEO x RN x PG2	0.000	0.000		0.000	0.000	0.000	0.000
JAM x PG2	0.219			0.000		0.000	0.000
PG1 x PG2			0.000	0.083		0.000	0.001
GEO x RN		0.000			0.000	0.000	0.000
GEO x PG2		0.000		0.000		0.000	0.000
GEO x RN x PG2		0.000		0.000	0.000	0.000	0.000
RN x PG2				0.000	0.916	0.000	0.727

Tabela 4.8: Tabela de Test t - Erro Médio da Árvore x Dados Normalizados

Experimentos	JAM	GEO	PG1	PG2	RN	OTIMO	ALEAT.
JAM x GEO	0.000	0.000				0.000	0.000
JAM x RN	0.000				0.000	0.000	0.000
JAM x GEO x RN	0.000	0.000			0.000	0.000	0.000
JAM x GEO x PG2	0.000	0.000		0.000		0.000	0.000
JAM x RN x PG2	0.000			0.000	0.000	0.000	0.000
JAM x GEO x RN x PG2	0.000	0.000		0.000	0.000	0.000	0.000
JAM x PG2	0.000			0.000		0.000	0.000
PG1 x PG2			0.000	0.000		0.000	0.000
GEO x RN		0.000			0.000	0.000	0.000
GEO x PG2		0.000		0.000		0.000	0.000
GEO x RN x PG2		0.000		0.000	0.000	0.000	0.000
RN x PG2				0.000	0.000	0.000	0.000

As Tabelas 4.7 e 4.8 contêm o p-valor resultante da aplicação do Teste t pareado bicaudal para todos os doze experimentos propostos. As colunas rotuladas com o nomes dos modelos contêm o p-valor resultante do Teste t aplicado aos Erros Médios obtidos com a aplicação do modelo para cada um dos registros da base em comparação aos Erros Médios obtidos através do modelo indicado pelo Meta-Aprendizado com árvores de decisão. As colunas “OTIMO” e “ALEAT.” contêm, respectivamente, o p-valor da comparação dos Erros Médios dos modelos ótimos e aleatórios de cada registro da base com os Erros Médios obtidos com os modelos indicados através do Meta-Aprendizado com as árvores de decisão. O resultado da aplicação do Teste t é utilizado na verificação da hipótese nula de igualdade da média dos valores de Erro Médio entre os grupos. No caso de dados normalizados, a comparação é realizada também com o Erro Médio normalizado indicado pelo Meta-Aprendizado.

Tabela 4.9: Comparativo Erro Médio Árvore x Erro Médio Modelos (% Melhora)

Experimentos	AE Árvore	AE JAM	AE GEO	AE PG1	AE PG2	AE RN	AE Aleat.	AE Ótimo
JAM x GEO	222.42	9.55	14.86				13.34	-12.81
JAM x RN	183.07	18.82				29.16	26.64	-5.24
JAM x GEO x RN	168.31	25.74	13.45			37.70	28.55	-7.42
JAM x GEO x PG2	163.10	20.95	9.31		33.02		23.74	-23.02
JAM x RN x PG2	133.38	24.35			49.96	19.26	33.23	-21.61
JAM x GEO x RN x PG2	140.41	36.21	15.44		42.89	32.23	35.37	-14.96
JAM x PG2	201.36	10.99			19.01		15.77	-22.15
PG1 x PG2	204.70			11.82	12.19		11.46	-31.85
GEO x RN	178.30		17.40			32.45	27.41	-5.00
GEO x PG2	195.61		14.84		25.15		18.98	-8.05
GEO x RN x PG2	153.11		24.93		41.96	27.00	33.54	-4.04
RN x PG2	206.86				16.21	11.09	10.50	-22.00
% Médio Melhora		20.95	15.75	11.82	30.05	26.98	23.21	-14.84




Figura 4.14: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão

Da Tabela 4.5 é possível compor a Tabela 4.9 com uma linha para cada experimento e calcular o percentual de casos em relação ao número de registros da base na qual o Erro Médio obtido utilizando a árvore de decisão é menor em comparação a algum modelo específico, a um modelo selecionado aleatoriamente e ao modelo ótimo. Os valores indicados na Tabela 4.9 podem ser considerados como percentual de melhora com relação ao Erro Médio na utilização do modelo indicado pela árvore de decisão. Os dados do experimento JAM x GEO também estão representados no gráfico da Figura 4.14, onde os percentuais de ganho estão representados. Os gráficos de ganho na utilização de Meta-Aprendizado com árvores de decisão dos demais experimentos estão na seção de apêndice deste documento.

4.4.1.1 Avaliação dos Resultados

O objetivo deste trabalho é verificar se a aplicação de técnicas de Aprendizado de Máquina em bases de dados empíricos, mais especificamente Meta-Aprendizado, pode ajudar a indicar qual o melhor modelo de confiabilidade a ser aplicado em um conjunto de dados. Neste sentido, as Tabelas 4.5, 4.6, 4.7, 4.8 e 4.9 fornecem uma visão consolidada dos resultados dos doze experimentos realizados e dos dados que podem ser extraídos destes experimentos.

A primeira conclusão que pode-se obter através da análise das Tabelas 4.7 e 4.8 é

que em todos os doze experimentos, a média do Erro Médio obtido através do Meta-Aprendizado com árvores de decisão, de um experimento não é equivalente a nenhuma outra média de Erro Médio utilizando um modelo de confiabilidade específico, ou os modelos ótimos ou aleatórios deste mesmo experimento, uma vez que o p-valor é menor que 5% em todas as aplicações do Teste t. Logo, a partir desta constatação pode-se afirmar que a hipótese nula de igualdade das médias das distribuições é descartada, assumindo a hipótese alternativa. Este resultado, estatisticamente suportado, permite afirmar que na média os resultados de Erro Médio obtidos através da aplicação de um modelo de confiabilidade arbitrário sobre uma base é diferente do resultado da aplicação do modelo indicado pelo Meta-Aprendizado utilizando árvores de decisão. Esta mesma conclusão estende-se para os modelos ótimos e modelos selecionados aleatoriamente para cada registro em comparação ao modelo do Meta-Aprendizado com árvores de decisão.

A Tabela 4.5 mostra que para todos os doze experimentos, quando se escolhe um modelo arbitrariamente, a soma do valor de Erro Médio é sempre maior que o valor de Erro Médio dos modelos indicados pela técnica de utilização de meta aprendizado (coluna AE Árvore). Além do Erro Médio (AE) dos modelos indicados pelas árvores de decisão serem menores que a escolha arbitrária de um modelo, o Erro Médio desta técnica é menor que a seleção aleatória de um modelo. Ou seja, se para cada registro da base de dados fosse sorteado um modelo dentre os que compõem o experimento, ainda assim o Erro Médio (AE) da árvore seria menor. Portanto, o Erro Médio obtido com a utilização das árvores de decisão é o menor possível dentre as hipóteses analisadas, ficando acima apenas do Erro Médio Ótimo, ou seja, o Erro Médio obtido da seleção do melhor modelo de confiabilidade para cada registro.

A relação de qual o ganho na utilização da técnica de aplicação de Aprendizado de Máquina na definição de qual o modelo de confiabilidade a ser utilizado pode ser observada na Tabela 4.9. Esta tabela é um complemento da Tabela 4.5, no sentido de indicar o percentual de ganho da utilização da árvore de decisão em relação a utilização de apenas um modelo ou a seleção de modelos aleatoriamente. Na Tabela 4.9 pode-se observar que o percentual médio de ganho na utilização da árvore é 20.95%, 15.75%, 11.82%, 30.05%,

26.98% com relação aos modelos JAM, GEO, PG1, PG2 e RN, respectivamente. Ou seja, a utilização da árvore é melhor que a escolha de um modelo arbitrariamente, com um resultado médio de ganho em relação ao Erro Médio de 21.11%. Quando comparado o resultado da seleção de um método aleatório com a utilização de meta aprendizado, os ganhos da utilização da árvore variaram de 10.50% a 35.37%, com um ganho médio de 23.21%. Na comparação do Erro Médio da árvore de decisão com o Erro Médio do modelo ótimo a árvore fica a apenas, na média, 14.84% do Erro Médio ótimo, com uma variação de 4.04% a 31.85%.

A Tabela 4.6 mostra a relação de acerto entre o modelo escolhido e o modelo ótimo para a base de dados. Nesta tabela, foi realizada a simulação da escolha de um modelo arbitrariamente, da seleção aleatória de um modelo e da utilização do modelo indicado pela aplicação da técnica proposta no trabalho, neste caso árvore de decisão. Para cada coluna foi calculado no número de casos em que o modelo arbitrário é igual ao modelo ótimo e o percentual de acerto em relação aos 310 registros de cada um dos doze experimentos. O mesmo foi realizado para o caso de seleção aleatória de um modelo e na utilização do modelo indicado pela árvore. No caso de modelos arbitrários a média de acerto fica em 41.90% considerando todos os doze experimentos. Já a escolha aleatória tem um percentual de acerto de 41.94% em relação ao modelo ótimo. O resultado mais próximo da indicação do modelo ótimo é obtido através das árvores de decisão. Na média, em 81.45% dos casos o modelo indicado pela árvore de decisão é igual ao melhor modelo para a base de dados. Este resultado comprova que a aplicação da técnica de Aprendizado Máquina para decisão de qual o melhor modelo representa um grande ganho no cálculo da confiabilidade de software. O resultado dos doze experimentos também é suportado pelos Testes t aplicados, que comprovam estatisticamente, que o conjunto de Erro Médio indicados pelas árvores de decisão são diferentes de todos os outros conjuntos: Modelos Comparados, Modelos Aleatórios e os Modelos Ótimos para cada registro.

4.4.2 Análise dos Resultados das Redes Neurais

Da mesma forma que foram produzidas as Tabelas 4.7 e 4.8 de aplicação do Teste t utilizando o Meta-Aprendizado com árvores de decisão, também foram produzidas as Tabelas 4.10 e 4.11 com os resultados da aplicação do Teste t considerando o Erro Médio resultante do Meta-Aprendizado com redes neurais.

Tabela 4.10: Tabela de Teste t - Erro Médio Rede Neural x Dados Não-Normalizados

Experimentos	JAM	GEO	PG1	PG2	RN	OTIMO	ALEAT.
JAM x GEO	0.000	0.000				0.000	0.000
JAM x RN	0.000				0.000	0.000	0.000
JAM x GEO x RN	0.000	0.001			0.000	0.000	0.000
JAM x GEO x PG2	0.004	0.051		0.000		0.000	0.000
JAM x RN x PG2	0.000			0.000	0.000	0.000	0.000
JAM x GEO x RN x PG2	0.000	0.022		0.000	0.000	0.000	0.000
JAM x PG2	0.159			0.000		0.000	0.000
PG1 x PG2			0.000	0.000		0.000	0.000
GEO x RN		0.000			0.000	0.001	0.000
GEO x PG2		0.000		0.000		****	0.000
GEO x RN x PG2		0.007		0.000	0.042	0.000	0.000
RN x PG2				0.000	0.224	0.000	0.074

Tabela 4.11: Tabela de Teste t - Erro Médio Rede Neural x Dados Normalizados

Experimentos	JAM	GEO	PG1	PG2	RN	OTIMO	ALEAT.
JAM x GEO	0.000	0.000				0.000	0.000
JAM x RN	0.000				0.000	0.000	0.000
JAM x GEO x RN	0.000	0.000			0.000	0.000	0.000
JAM x GEO x PG2	0.000	0.000		0.000		0.000	0.000
JAM x RN x PG2	0.000			0.000	0.000	0.000	0.000
JAM x GEO x RN x PG2	0.000	0.000		0.000	0.000	0.000	0.000
JAM x PG2	0.000			0.000		0.000	0.000
PG1 x PG2			0.000	0.000		0.000	0.000
GEO x RN		0.000			0.000	0.001	0.000
GEO x PG2		0.000		0.000		****	0.000
GEO x RN x PG2		0.000		0.000	0.000	0.000	0.000
RN x PG2				0.000	0.000	0.000	0.000

Tabela 4.12: Comparativo Erro Médio Rede Neural x Erro Médio Modelos (% Melhora)

Experimentos	AE Rede Neural	AE JAM	AE GEO	AE PG1	AE PG2	AE RN	AE Aleat.	AE Ótimo
JAM x GEO	219.70	10.66	15.91				14.40	-11.43
JAM x RN	179.71	20.31				30.46	27.98	-3.31
JAM x GEO x RN	176.27	22.23	9.36			34.75	25.17	-12.50
JAM x GEO x PG2	162.32	21.33	9.73		33.34		24.10	-22.44
JAM x RN x PG2	137.37	22.08			48.46	16.84	31.23	-25.24
JAM x GEO x RN x PG2	138.29	37.17	16.72		43.75	33.25	36.34	-13.23
JAM x PG2	200.13	11.54			19.50		16.28	-21.40
PG1 x PG2	172.69			25.61	25.92		25.30	-11.23
GEO x RN	172.89		19.91			34.50	29.61	-1.81
GEO x PG2	181.03		21.18		30.73		25.01	0.00
GEO x RN x PG2	166.21		18.50		36.99	20.76	27.85	-12.93
RN x PG2	192.46				22.04	17.28	16.73	-13.51
% Médio Melhora		20.76	15.90	25.61	32.59	26.83	25.00	-12.42

Também da mesma forma que a Tabela 4.9 foi composta com os percentuais de melhora com relação ao Erro Médio, com a utilização de árvores de decisão, a Tabela 4.12 contém uma linha para cada experimento indicando os percentuais de melhora com a utilização de Meta-Aprendizado com redes neurais.

4.4.2.1 Avaliação dos Resultados

Da mesma maneira que na avaliação dos resultados do Meta-Aprendizado realizado com árvores de decisão, as Tabelas 4.5, 4.6, 4.10, 4.11 e 4.12 apresentam uma visão consolidada dos resultados dos doze experimentos.

Da análise das Tabelas 4.10 e 4.11, para todos os doze experimentos, obtemos as mesmas conclusões que as tabelas com os resultados da aplicação do Teste t com o Meta-Aprendizado com árvores de decisão apresentou anteriormente. Isto é, a média do Erro Médio obtido através do Meta-Aprendizado com rede neural não é equivalente a nenhuma outra média de Erro Médio, seja utilizando um modelo de confiabilidade específico, ou os modelos ótimos ou aleatórios deste mesmo experimento. A exceção para o Teste t de comparação do Erro Médio dos modelos indicados pela rede neural e o modelo ótimos dos registros da base ocorre no experimento de comparação entre os modelos GEO e PG2. Neste experimento, os modelos indicados pela rede neural são exatamente os modelos ótimos para cada registro (detalhes deste experimento podem ser vistos nas tabelas no Apêndice J).

Já a Tabela 4.5 quando analisada sobre o foco de Meta-Aprendizado com redes neurais, além das mesmas conclusões obtidas com árvores de decisão, reforça que sempre a soma do valor de Erro Médio (coluna AE Rede Neural) obtido com o Meta-Aprendizado é menor que a escolha arbitrária ou aleatória de um modelo qualquer dentre os pertencentes ao experimento. O Erro Médio obtido com Meta-Aprendizado com redes neurais só não é melhor que o Erro Médio dos Modelos Ótimos, no entanto, ainda assim o valor de Erro Médio é muito próximo ao ótimo.

A relação de qual o ganho na utilização da técnica de aplicação de Aprendizado de Máquina na definição de qual o modelo de confiabilidade a ser utilizado pode ser observado na Tabela 4.12. Esta tabela é um complemento da Tabela 4.5, no sentido de indicar o percentual de ganho da utilização de rede neural em relação à utilização de apenas um modelo ou à seleção de modelos aleatoriamente. Na Tabela 4.12 pode-se observar que o percentual médio de ganho na utilização do Meta-Aprendizado é 20.76%, 15.90%, 25.61%, 32.59%, 26.83% com relação aos modelos JAM, GEO, PG1, PG2 e RN, respectivamente.

Ou seja, a utilização do Meta-Aprendizado com rede neural é melhor que a escolha de um modelo arbitrariamente, com um resultado médio de ganho em relação ao Erro Médio de 24.84%. Quando comparado ao resultado da seleção de um método aleatório com a utilização de Meta-Aprendizado, os ganhos da utilização de rede neural variaram de 14.40% a 36.34%, com um ganho médio de 25%. Na comparação do Erro Médio da rede neural com o Erro Médio do modelo ótimo, o Meta-Aprendizado fica apenas, na média, 12.42% do Erro Médio ótimo, com uma variação de 0% a 25.24%.

A análise dos dados do Meta-Aprendizado com rede neural da Tabela 4.6 mostra que o resultado mais próximo da indicação do modelo ótimo é obtido através do Meta-Aprendizado com rede neural. Na média, em 85.48% dos casos o modelo indicado pela rede neural é igual ao melhor modelo para a base de dados. Este resultado comprova que a aplicação da técnica de Aprendizado Máquina para decisão de qual o melhor modelo representa um grande ganho no cálculo da confiabilidade de software. O resultado dos doze experimentos também é suportado pelos Testes t aplicados, que comprovam estatisticamente, que o conjunto de Erro Médio indicados pela rede neural são diferentes de todos os outros conjuntos: Modelos Comparados, Modelos Aleatórios e os Modelos Ótimos para cada registro, com exceção do experimento **GEO x PG2**, onde a rede neural indicou exatamente o modelo ótimo para cada registro.

4.4.3 Comparação Entre o Resultado de Árvores de Decisão e Redes Neurais

Para a realização dos experimentos foram utilizados dois tipos de algoritmos para o Meta-Aprendizado, algoritmo com árvores de decisão e com redes neurais. A partir dos resultados foi feita uma análise comparando os resultados dos dois algoritmos. A rede neural obteve uma pequena vantagem no que diz respeito a indicação de modelos de confiabilidade mais próximos do ótimo, 81.45% de árvores de decisão contra 85.48% de redes neurais. No caso do experimento **GEO x PG2** o Meta-Aprendizado com rede neural indicou exatamente os melhores modelos para cada base com relação ao Erro Médio (*AE*). Outros resultados positivos na utilização de rede neural sobre árvores de decisão foram obtidos na

comparação com modelos selecionados aleatoriamente ou escolhidos arbitrariamente, com ganhos médios de 1.79% (25% - 23.21%) e 3.23% (24.34% - 21.11%), respectivamente. No entanto, apesar de o Meta-Aprendizado com rede neural ser um pouco superior ao com árvores de decisão nos resultados dos experimentos, as árvores de decisão apresentam a vantagem de serem mais legíveis aos humanos.

4.5 Considerações Finais

Este capítulo introduziu uma abordagem de seleção de modelos de confiabilidade de software com algoritmos de Meta-Aprendizado. Para avaliar a abordagem proposta foram realizados diversos experimentos utilizando os algoritmos de Aprendizado de Máquina baseados em árvores de decisão e Redes Neurais para seleção dos modelos baseados no tempo.

A aplicação de Meta-Aprendizado de Máquina em atividades de Engenharia de Software é um ferramenta importante no auxílio à tomada de decisões. Um fator determinante para geração de regras precisas é a disponibilidade de dados históricos para análise e a identificação de características nos dados desta base que podem influenciar na tomada de decisão. Esta escolha de qual característica da base é determinante e está intimamente relacionada ao problema.

No caso de confiabilidade de software foram escolhidas variáveis que estivessem ligadas ao intervalo de identificação das falhas, ao ruído da curva de estabilização da confiabilidade e a identificação de quão acentuada era a variação dos dados (auto-correlação). Neste caso, o meta-aprendizado apresentou resultados bastante satisfatórios considerando a aplicação de um algoritmo baseado em árvore de decisão e melhores ainda com um algoritmo de Redes Neurais. Os resultados mostraram a viabilidade e os ganhos em aplicar as técnicas de Aprendizado de Máquina para ajudar a decidir qual o modelo de confiabilidade utilizar.

CAPÍTULO 5

CONCLUSÃO

Este trabalho apresentou uma proposta de aplicação de técnicas de Aprendizado de Máquina em uma área especialmente crítica na produção de software de qualidade: a avaliação da confiabilidade de software. O trabalho propôs uma abordagem de Meta-Aprendizado para auxiliar na indicação de qual o melhor modelo de confiabilidade, ou seja, selecionar o modelo que apresenta o melhor resultado na estimativa da confiabilidade de software de acordo com algumas características das bases de dados de confiabilidade.

Para validar a abordagem proposta foram realizados experimentos de seleção entre diversos modelos de confiabilidade baseados no tempo entre falhas. Foram utilizados os modelos tradicionais JAM e GEO, e modelos não paramétricos baseados em Programação Genética e Redes Neurais. Como técnicas de Aprendizado de Máquina foram avaliados algoritmos baseados em árvores de decisão e Redes Neurais. Ao todo foram realizados doze experimentos de comparação entre os modelos, aplicando o algoritmo J48 e *MultilayerPerceptron* do aplicativo Weka [102] para geração das árvores de decisão e redes neurais na indicação de qual o melhor modelo de confiabilidade para base em estudo (Meta-Aprendizado).

Foram utilizados como atributos para o Meta-Aprendizado (Meta-dados) os valores de Variância, Inclinação, Auto-Correlação e Ruído Médio calculados a partir do tempo entre falhas coletados dos projetos que compõem a base do centro de dados e análise de software - DACS. Neste trabalho, utilizou-se o valor do Erro Médio para definir qual modelo apresentou o melhor resultado para um dado conjunto de dados.

Os resultados obtidos em todos os doze experimentos utilizando Meta-Aprendizado com árvores de decisão mostram que a utilização da abordagem proposta no trabalho, acerta, em média, quanto ao melhor modelo de confiabilidade para uma dada base de dados, com relação ao Erro Médio, em 81.45% dos casos. Além disso, na comparação

entre a utilização do método proposto de utilização de Meta-Aprendizado com uma seleção aleatória de um modelo de confiabilidade, a utilização de Meta-Aprendizado apresenta um ganho médio de 23.71% com relação ao Erro Médio. Já na comparação dos resultados de Meta-Aprendizado com a escolha arbitrária de se utilizar sempre um mesmo modelo de confiabilidade, o Meta-Aprendizado com árvores de decisão resultou em um ganho médio de 21.46% também em relação ao Erro Médio.

Da mesma forma que o Meta-Aprendizado com árvores de decisão apresentou resultados satisfatórios, o Meta-Aprendizado com Rede Neural trouxe resultados ainda melhores. Em uma avaliação geral, em 85.48% dos casos, o modelo apontado pelo Meta-Aprendizado é igual ao modelo ótimo para a base considerando o Erro Médio. Outro resultado positivo ocorre na avaliação do Erro Médio obtido com o Meta-Aprendizado com Rede Neural contra a seleção aleatória de um modelo de confiabilidade. Na média, o ganho é de 25%. O mesmo ocorre na comparação com a seleção arbitrária de um modelo, onde o ganho médio varia de 15.90% a 32.59%.

Logo, os resultados obtidos nos doze experimentos de comparação entre modelos de confiabilidade (JAM, GEO, PG1, PG2, RN) mostrou que a aplicação de Meta-Aprendizado, independentemente do algoritmo utilizar árvores de decisão ou redes neurais, consegue indicar com maior precisão, considerando o menor valor de Erro Médio dos modelos, qual o melhor modelo de confiabilidade para ser utilizado em uma dada base de dados em comparação a escolha arbitrária ou seleção aleatória de um modelo.

5.1 Trabalhos Futuros

Este trabalho contribuiu com uma nova aplicação das técnicas de Aprendizado de Máquina, especialmente a sub-área de Meta-Aprendizado, para seleção de qual modelo de confiabilidade aplicar a um projeto quando os dados do tempo entre falhas apresenta algumas características. Novos trabalhos e variações de aplicação da abordagem proposta podem ser realizados através da utilização de outros algoritmos de Aprendizado de Máquina. Neste trabalho foram utilizados os algoritmos J48 e *MultilayerPerceptron* para realização do aprendizado. Outros algoritmos que podem, por exemplo, serem utilizados são Pro-

gramação Genética e descoberta de regras (Apriori).

Além da abordagem com outros algoritmos de Aprendizado de Máquina, a técnica proposta neste trabalho pode ser aplicada sobre outros atributos (Meta-Dados) das bases de dados. A escolha de outros atributos, como outras medidas estatísticas, para realização do Meta-Aprendizado pode fornecer resultados ainda mais precisos quanto ao melhor modelo.

Outros experimentos também podem ser conduzidos utilizando a abordagem com um outro conjunto de confiabilidade e para a seleção de outros tipos de modelos de confiabilidade. Além disso, existem inúmeras outras áreas de Engenharia de Software nas quais a utilização de Meta-Aprendizado merece ser investigada como as atividades de planejamento de projeto, testes e manutenção.

BIBLIOGRAFIA

- [1] R. Agrawal, T. Imielinski, e A. N. Swami. Mining association rules between sets of items in large databases. *Special Interest Group on Management Of Data (SIGMOD)*, Junho de 1993.
- [2] R. Agrawal e R. Srikant. Fast algorithms for mining association rules. *Proceddings of the 20th VLDB Conference*, Setembro de 1994.
- [3] S. H. Aljahdali, A. Sheta, e D. Rine. Prediction of software reliability: a comparison between regression and neural network non-parametric models. *ACS/IEEE International Conference on Computer Systems and Applications*, páginas 470–473, 2001.
- [4] M. Almeida, H. Lounis, e W. Melo. An investigation on the use of machine learned models for estimating correction costs. *Proc. of International Conference on Software Engeneering*, 1998.
- [5] M. Almeida e S. Matwin. Machine learning method for software quality model building. *Proc. of International Symposium on Methodoligies for Intelligent Systems*, 1999.
- [6] Ch. Ali Asad, Irfan Ullah Muhammad, e Jaffar-Ur Rehman Muhammad. An approach for software reliability model selection. *Proceedings of the 28th Annual International Computer Software and Applications Conference*, 2004.
- [7] S. C. Bailin, R. H. Gattis, e W. Truszkowski. A learning-based software engineering environment. *Proc. of the Sixth Annual Knowledge-Based Software Engineering Conference*, Syracuse, N.Y., 1991.
- [8] V. R. Basili, Steven E. C., K. El Emam, R. B. Hendrick, e L. W. Melo. Characterizing and modeling the cost of rework in a library of reusable software components. *19 International Conference on Software Engineering (ICSE)*, Maio de 1997.

- [9] G. E. A. P. A. Batista. *Pré-Processamento de Dados em Aprendizado de Máquina Supervisionado*. Tese de Doutorado, ICMC - USP, São Carlos, Brasil, Março de 2003.
- [10] F. Bergadano e D. Gunetti. Testing by means of inductive program learning. *IEEE Transactions on Software Engineering*, 5(2), Abril de 1996.
- [11] S. Bhansali e M. T. Harandi. Synthesis of unix programs using derivational analogy. *Machine Learning*, 10, Janeiro de 1993.
- [12] I. Bratko e M. Grobelnik. Inductive learning applied to program construction and verification. *Proc. Third International Workshop on Inductive Logic Programming*, Bled, Slovenia, 1993.
- [13] L. C. Briand, V. Basili, e W. Thomas. A pattern recognition approach for software engineering data analysis. *IEEE Trans. on Software Engineering*, 18(11), Novembro de 1992.
- [14] L. C. Briand, V. R. Basili, e C. J. Hetmanski. Developing interpretable models with optimized set reduction for identifying high-risk software components. *IEEE Transactions on Software Engineering*, 19(11), Novembro de 1993.
- [15] L. C. Briand, K. El Eman, K. D. Maxwell, D. Surmann, e I. Wiecek. An assessment and comparison of common software cost estimation modeling techniques. *21th International Conference of Software Engineering*, Maio de 1999.
- [16] C.K. Chang, M.J. Christensen, e T. Zhang. Genetic algorithms for project management. *Annals of Software Engineering*, 11, Novembro de 2001.
- [17] N.V. Chawla, K.W. Bowyer, L.O. Hall, e W.P. Kegelmeyer. Smote: Synthetic minority over-sampling technique. *Journal of Artificial Intelligence Research*, 16:321–357, 2002.
- [18] N.V. Chawla, N. Japkowicz, e A. Kotcz. Editorial: Special issue on learning from imbalanced data sets. *ACM SIGKDD Explorations*, 6:1–6, 2004.

- [19] N.H. Chen, M. R. Lyu, e W. E. Wong. An empirical study of the correlation between code coverage and reliability estimation. *Third International Software Metrics Symposium*, páginas 133–141. IEEE Computer Society, 1996.
- [20] S. Choi e C. Wu. Partitioning and allocation of objects in heterogeneous distributed environments using the Niched Pareto Genetic-algorithm. *APSEC '98: Proceedings of the Fifth Asia Pacific Software Engineering Conference*, 1998.
- [21] S. Chulani, B. Boehm, e B. Steece. Bayesian analysis of empirical software engineering cost models. *IEEE Transaction on Software Engineerining*, 25(4), Julho de 1999.
- [22] W. W. Cohen. Inductive specification recovery: Understanding software by learning from example behaviors. *Automated Software Engineering*, 2, 1995.
- [23] W. W. Cohen e P. Devanbu. A comparative study of inductive logic programming methods for software fault prediction. *Proc. 14th International Conference on Machine Learning*. Morgan Kaufmann, 1997.
- [24] J. E. Cook e A. L. Wolf. Discovering Models of Software Processes from Event-Based Data. *ACM Transactions on Software Engineering and Methodology*, 7(3), 1998.
- [25] E. O. Costa, G. A. Souza, A. Pozo, e S. R. Vergilio. Exploring genetic programming and boosting techniques to model software reliability. *IEEE Transaction on Software Reliability*, 2007.
- [26] E. O. Costa, S. R. Vergilio, A. Pozo, e G. A. Souza. Modeling software reliability growth with genetic programming. *Internation Symposium of Software Reliability Engineering*, 2005.
- [27] A. N. Crespo. *Modelos de confiabilidade de software baseados em cobertura de critérios estruturais de teste*. Tese de Doutorado, Unicamp - DCA-FEEC, Brasil, 1997.

- [28] M. E. Delamaro, J. C. Maldonado, e M. Jino. Confiabilidade. *Introdução ao Teste de Software*. Ed. Campus, 2007.
- [29] T. Dohi, Y. Nishio, e S. Osaki. Optimal software release scheduling based on artificial neural networks. *Annals of Software Engineering*, 8, 1999.
- [30] J. J. Dolado. A validation of the component-based method for software size estimation. *IEEE Transactions on Software Engineering*, 26(10), Outubro de 2000.
- [31] C. Drummond, D. Ionescu, e R. Holte. A learning agent that assists the browsing of software libraries. *International Transactions on Software Engineering (IEEE)*, 26(12), 2000.
- [32] K. El Emam, S. Benlarbi, N. Goel, e S.N. Rai. Comparing case-based reasoning classifiers for predicting high risk software components. *Journal of Systems and Software*, 55, 2001.
- [33] M. Evett, T. Khoshgoftar, P. Chien, e E. Allen. GP-based software quality prediction. *Genetic Programming 1998: Proceedings of the Third Annual Conference*, University of Wisconsin, Madison, Wisconsin, USA, 1998. Morgan Kaufmann.
- [34] N. E. Fenton e M. Neil. A critique of software defect prediction models. *International Transactions on Software Engineering (IEEE)*, 25(3), 1999.
- [35] G. Fouque e S. Matwin. Caesar: a system for case based software reuse. *In Proc. of 7th Knowledge-Based Software Engineering Conference*, 1992.
- [36] K. Ganesan, T. M. Khoshgoftaar, e E.B. Allen. Case-based software quality prediction. *International Journal of Software Engineering and Knowledge Engineering*, 9(6), 1999.
- [37] P. K. Garg e S. Bhansali. Process programming by hindsight. *International Conference on Software Engineering*, Maio de 1992.

- [38] R. J. Hall. Systematic incremental validation of rule-based reactive systems. *Proc. of the 9th Knowledge-Based Software Engineering Conference (KBSE'94)*, Monterey, CA, 1994.
- [39] R. J. Hall. Explanation-based scenario generation for reactive system models. *Automated Software Engineering*, 7(2), Maio de 1998.
- [40] M. T. Harandi e H.-Y. Lee. Acquiring software design schemas: A machine learning perspective. *Proc. of the Sixth Annual Knowledge-Based Software Engineering Conference*, Syracuse, N.Y., 1991.
- [41] W. L. Hill. Machine learning for software reuse. *Proceedings of the Tenth International Joint Conference on Artificial Intelligence*, Milan, Italy, 1987. Morgan Kaufmann.
- [42] J. Holland. *Adaptation in natural and artificial systems*. MIT Press, 1975.
- [43] E. Hong e C. Wu. Criticality models using sdl metrics set. *Proceedings of the 4th Asia-Pacific Software Engineering and International Computer Science Conference*, 1997.
- [44] M. Jorgensen. Experience with the accuracy of software maintenance task effort prediction models. *TSE*, 21(8), 1995.
- [45] S. V. Kartalopoulos. Understanding neural networks and fuzzy logic: Basic concepts and applications. *Institute of Electrical and Electronics Engineers*, 1996.
- [46] S. Kartalopoulos. *Understanding Neural Networks and Fuzzy Logic: Basic Concepts and Applications*. IEEE Press, 1996.
- [47] N. Karunanithi, D. Whitely, e Y. Malaiya. Prediction of software reliability using connectionist models. *International Transactions on Software Engineering (IEEE)*, 1992.
- [48] P. Katalagarianos. On the reuse of software: (a) case-based approach employing a repository. *Automated Software Engineering*, 2, 1995.

- [49] T. M. Khoshgoftaar, E. B. Allen, e Z. Xu. Predicting testability of program modules using a neural network. *Proceedings: Symposium on Application-Specific Systems and Software Engineering Technology*, Richardson, Texas USA, Março de 2000.
- [50] T.M. Khoshgoftaar, A.S. Pandya, e D.L. Lanning. Application of neural networks for predicting faults. *Annals of Software Engineering*, 1, 1995.
- [51] T.M. Khoshgoftaar e T.G Woodcock. Software reliability model selection: A case study. *Proceedings of the 2nd International Symposium on Software Reliability Engineering*, 1991.
- [52] R. Kohavi. A study of cross-validation and bootstrap for accuracy estimation and model selection. *International Conference on Artificial Intelligence*, 1, 1995.
- [53] J. Koza. *Genetic Programming: on the programming of computers by means of natural selection*. MIT Press, 1992.
- [54] P.B. Lakey e A.M. Neufelder. *System and Software Reliability Assurance Notebook*. Rome Laboratory, 1997.
- [55] A. Lamsweerde e L. Willemet. Inferring declarative requirements specifications from operational scenarios. *IEEE Transactions on Software Engineering*, 24(12), Dezembro de 1998.
- [56] W. B. Langdon. Evolving data structures using genetic programming. Reseach note, UCL, Janeiro de 1995.
- [57] F. Lanubile e G. Visaggio. Evaluating predictive quality models derived from software measures: Lessons learned. *j-J-SYST-SOFTW*, 38(3), Setembro de 1997.
- [58] D.B. Leake e D.C. Wilson. A case-based framework for interactive capture and reuse of design knowledge. *Applied Intelligence*, 14, 2001.
- [59] B.-J. Lee, B.-R. Moon, e C.-S. Wu. Optimization of multi-way clustering and retrieval using genetic algorithms in reusable class library. *APSEC '98: Proceedings of the Fifth Asia Pacific Software Engineering Conference*, 1998.

- [60] M. Lipow. Models for software reliability. *Proceedings of the Winter Meeting of the Aerospace Division of the American Society of Mechanical Engineers*. WA/Aero-18, 1978.
- [61] M. R. Lyu. *Handbook of Software Reliability Engineering*. McGraw-Hill IEEE Computer Society Press, 1996.
- [62] Y. K. Malaiya, M. N. Li, J.M. Bieman, e R. Karcich. Software reliability growth with test coverage. *IEEE Transactions on Reliability*, 51(4):420–426, 2002.
- [63] Y. Mao, H. Sahraoui, e H. Lounis. Reusability hypothesis verification using machine learning techniques: A case study. *ASE '98: Proceedings of the 13th IEEE international conference on Automated software engineering*, 1998.
- [64] G. McGraw e C.C. Michael. Automated software test data generation for complex programs. *Proceedings of the 13th International Automated Software Engineering Conference*, Honolulu, Hawaii, Outubro de 1998.
- [65] T. Menzies. *Practical Machine Learning for Software Engineering and Knowledge Engineering*. World Scientific Publishing Company, 2000.
- [66] C. C. Michael, G. McGraw, e M. Schatz. Generating software test data by evolution. *IEEE Transactions on Software Engineering*, 27(12), Dezembro de 2001.
- [67] S. Minton e S. R. Wolfe. Using machine learning to synthesize search programs. *Proc. of the 9th Knowledge-Based Software Engineering Conference (KBSE'94)*, Monterey, CA, 1994.
- [68] T.M. Mitchell. *Machine Learning*. The McGraw-Hill Companies, Inc., 1997.
- [69] A. Mood, F. Graybill, e D. Boes. *Introduction to the Theory of Statistics*. McGraw-Hill, 3 edition, 1974.
- [70] P. Moranda. Predictions of software reliability during debbuging. *Proceddings of the Annual Reliability Maintainability Symposion*, 1975.

- [71] P. Moranda e Z. Jelinski. Final report on software reliability study. Relatório técnico, McDonnall Douglas Astronautics Company, 1972.
- [72] J. D. Musa, A. Ianino, e K. Okumoto. *Software Reliability - Measurement, Prediction, Application*. McGraw-Hill, 1987.
- [73] J.D. Musa. The software reliability dataset. Disponível em <http://www.dacs.dtic.mil/databases/sled/swrel.shtml> (2007).
- [74] J.D Musa. A theory of software reliability and its application. *IEEE Transactions on Software Engineering*, páginas 312–327, 1975.
- [75] E. Ostertag, J. Hendler, R. P. Díaz, e C. Braun. Computing similarity in a reuse library system: an AI-based approach. *Transactions on Software Engineering and Methodology (j-TOSEM)*, 1(3), Julho de 1992.
- [76] D. Partridge, W. Wang, e P. Jones. Artificial intelligence techniques for system software enhancement. Relatório técnico, School of Engeneering and Computer Science, University of Exeter,U.K., 2001.
- [77] A. Pasquine, A. N. Crespo, e P. Matrella. Sensitivity of reliability growth models to operational profile erros vs testing accuracy. *IEEE Transactions on Reliability*, 45(4):531–540, 1996.
- [78] A.A. Porter e R.W. Selby. Empirically guided software development using metric-based classification trees. *IEEE Transactions on Software Engineering*, 7(2), Março de 1990.
- [79] W. H. Press, A. S. Teukolsky, W. T. Vetterling, e B. P. Flannery. *Numerical Recipes in C: The Art of Scientific Computing*. Cambridge University Press, 1992.
- [80] R.B.C. Prudencio e T.B. Ludermir. Meta-learning approaches to selecting time series models. *Neurocomputing Journal*, 2004.
- [81] R.B.C. Prudencio, T.B. Ludermir, e F.A.T. Carvalho. A modal symbolic classifier to select time series models. *Pattern Recognition Letters*, 2004.

- [82] J. R. Quinlan. *C4.5 Program for Machine Learning*. Morgan Kaufmann Publishers, 1993.
- [83] A. Qureshi. Evolving agents. *Genetic Programming 1996: Proceedings of the First Annual Conference*, Stanford University, CA, USA, 1996. MIT Press.
- [84] S. O. Rezende. *Sistemas Inteligentes - Fundamentos e Aplicações*. Editora Manole Ltda, 2003.
- [85] C. Ryan. An automatic software re-engineering tool based on genetic programming. *Advances in Genetic Programming*, 1999.
- [86] C. Ryan. *Automatic re-engineering of software using genetic programming*. Kluwer Academic Publishers, 2000.
- [87] K. A. Salwa. Identifying objects in procedural programs using clustering neural networks. *Automated Software Eng.*, 7(3), 2000.
- [88] P.M. Santos, T.B. Ludemir, e R.B.C. Prudencio. Selection of time series forecasting models based on performance information. *Proceedings of Fourth International Conference on Hybrid Intelligent Systems (HIS 04)*, Japan, 2004.
- [89] G. J. Schick e R. W. Wolverton. Assessment of software reliability. *Proceedings of the Operation Research*. Physica-Verlag, 1973.
- [90] N. F. Schneidwind. An analysis of competing software reliability models. *Sigplan Notes*. Physica-Verlag, 1953.
- [91] R.W. Schwanke e S.J. Hanson. Using neural networks to modularize software. Submitted to *Machine Learning*, 1993.
- [92] R. W. Selby e A. A. Porter. Learning from examples: Generation and evaluation of decision trees for software resource analysis. *Australian Academy of Technological Sciences and Engineering (AATSE)*, 14(12), Dezembro de 1988.

- [93] M. Shepperd e C. Schofield. Estimating software project effort using analogies. *IEEE Transactions on Software Engineering*, 23(11), 1997.
- [94] K.K. Shukla. Neuro-genetic prediction of software development effort. *Information and Software Technology*, 42, 2000.
- [95] M. P. S. Silva. Mineração de dados - conceitos, aplicações e experimentos com weka. Relatório técnico, Universidade do Estado do Rio Grande do Norte (UERN) e Instituto Nacional de Pesquisas Espaciais (INPE), 2004.
- [96] R. Sitte. Comparison of software reliability growth predictions: neural networks vs parametric recalibration. *IEEE Transactions on Software Engineering*, 48(3):285–291, Setembro de 1999.
- [97] I. Sommerville. *Software engineering*. Addison-Wesley, 1996.
- [98] K. Srinivasan e D. Fischer. Machine learning approaches to estimating software development effort. *IEEE Transactions on Software Engineering*, 1995.
- [99] UFPA. Biometria - algumas distribuições. Disponível em <http://www2.ufpa.br/dicas/biome/biodist.htm>, Outubro de 2007.
- [100] S. Vicinanza, M.J. Prietulla, e T. Mukhopadhyay. Case-based reasoning in software effort estimation. *In Proc. of 11th International Conference on Information Systems*, Stanford University, CA, USA, 1990. MIT Press.
- [101] R. Vilalta, Giraud-Carrier, e P. C., Brazdil. *Meta-Learning: Concepts and Techniques. Data Mining and Knowledge Discovery Handbook*. O. Maimon & L. Rokach, 2005.
- [102] Univeridade Waikato. Weka - machine lerning software in java. Disponível no site da Universidade of Waikato(2006). <http://www.cs.waikato.ac.nz/ml/weka>.
- [103] Wikipedia. Meta learning (computer science). Disponível em http://en.wikipedia.org/wiki/Meta_Learning_Computer_Science acessado em 2007.

- [104] D. Zhang e J.J.P Tsai. Machine learning and software engeneering. Relatório técnico, California State University, 2003.

APÊNDICE A

EXPERIMENTO JAM X GEO

Tabela A.1: Experimento JAM x GEO

Num. Registro	Base	Variância	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE GEO	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	GEO	7.69	14.39	7.69	JAM	14.39	JAM	14.39	JAM	14.39
2	DS2	0.03944	0.45466	0.37182	0.1618	GEO	6.46	22.42	6.46	GEO	6.46	GEO	6.46	JAM	22.42
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	19.48	9.8	GEO	9.8	GEO	9.8	JAM	19.48
4	DS4	0.03793	0.70296	0.43633	0.05507	JAM	10.59	10.59	14.55	GEO	10.59	JAM	10.59	JAM	10.59
5	DS5	0.01651	0.04997	0.13836	0.11496	GEO	17.41	20.459999	17.41	JAM	20.459999	JAM	20.459999	GEO	17.41
6	DS6	0.02785	0.19466	0.00867	0.14702	GEO	15.72	18.6	15.72	GEO	15.72	GEO	15.72	JAM	18.6
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	7.85	JAM	6.21	JAM	6.21	JAM	6.21
8	DS27	0.03109	0.56245	0.71428	0.06449	GEO	12.24	18.5	12.24	JAM	18.5	JAM	18.5	GEO	12.24
9	DS40	0.02924	0.2158	0.35269	0.1444	JAM	14.5	14.5	28.030001	GEO	28.030001	GEO	28.030001	GEO	28.030001
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	GEO	13.1	14.41	13.1	GEO	13.1	GEO	13.1	GEO	13.1
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	GEO	9.41	9.88	9.41	GEO	9.41	GEO	9.41	JAM	9.88
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.67	5.44	GEO	5.44	GEO	5.44	JAM	5.67
13	SINT-7-9	0.03275	0.3922	0.103233	0.091037	JAM	8.282499	8.282499	12.895	JAM	8.282499	JAM	8.282499	GEO	12.895
14	SINT-7-9	0.03041	0.2746	0.269538	0.126612	JAM	12.4275	12.4275	22.985001	GEO	22.985001	GEO	22.985001	GEO	22.985001
15	SINT-4-14	0.03605	0.59587	0.394632	0.072956	JAM	11.049376	11.049376	16.658751	JAM	11.049376	JAM	11.049376	GEO	16.658751
16	SINT-4-14	0.03229	0.38169	0.311236	0.108727	JAM	11.968124	11.968124	20.876251	JAM	11.968124	JAM	11.968124	GEO	20.876251
17	SINT-15-16	0.03511	0.542325	0.373783	0.081898	JAM	11.279062	11.279062	17.713127	JAM	11.279062	JAM	11.279062	GEO	17.713127
18	SINT-15-16	0.03323	0.435235	0.332085	0.099784	JAM	11.738438	11.738438	19.821877	JAM	11.738438	JAM	11.738438	JAM	11.738438
19	SINT-17-18	0.03464	0.515553	0.363358	0.08637	JAM	11.393906	11.393906	18.240314	JAM	11.393906	JAM	11.393906	JAM	11.393906
20	SINT-17-18	0.0337	0.462008	0.342509	0.095313	JAM	11.623594	11.623594	19.294689	JAM	11.623594	JAM	11.623594	JAM	11.623594
21	SINT-15-20	0.035462	0.562404	0.381601	0.078545	JAM	11.19293	11.19293	17.317734	JAM	11.19293	JAM	11.19293	JAM	11.19293
22	SINT-15-20	0.034287	0.495473	0.35554	0.089723	JAM	11.48004	11.48004	18.635704	JAM	11.48004	JAM	11.48004	GEO	18.635704
23	SINT-16-22	0.032789	0.410136	0.322312	0.103976	JAM	11.846104	11.846104	20.316114	JAM	11.846104	JAM	11.846104	JAM	11.846104
24	SINT-16-22	0.033788	0.467027	0.344464	0.094474	JAM	11.60206	11.60206	19.195841	JAM	11.60206	JAM	11.60206	JAM	11.60206
25	SINT-19-24	0.034427	0.503421	0.358635	0.088396	JAM	11.445944	11.445944	18.479197	JAM	11.445944	JAM	11.445944	JAM	11.445944
26	SINT-19-24	0.034001	0.479159	0.349187	0.092448	JAM	11.550022	11.550022	18.956959	JAM	11.550022	JAM	11.550022	JAM	11.550022
27	SINT-2-12	0.037617	0.363245	0.270775	0.160605	GEO	6.205	6.205	6.205	GEO	6.205	GEO	6.205	GEO	6.205
28	SINT-2-12	0.033973	0.180415	0.068685	0.158215	GEO	5.695	5.695	5.695	GEO	5.695	GEO	5.695	JAM	5.695
29	SINT-3-28	0.060828	0.562716	0.314051	0.165591	GEO	8.77375	17.074375	8.77375	GEO	8.77375	GEO	8.77375	JAM	17.074375
30	SINT-3-28	0.042924	0.307849	0.150474	0.160674	GEO	6.72125	12.263124	6.72125	GEO	6.72125	GEO	6.72125	JAM	12.263124
31	SINT-8-30	0.034049	0.4988	0.573328	0.088536	GEO	10.860312	16.940781	10.860312	JAM	16.940781	JAM	16.940781	JAM	16.940781

Tabela A.2: Experimento JAM x GEO - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE JAM	AE GEO	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	JAM	14.39	0.534398888	1	0.534398888	1	1	1
2	DS2	JAM	22.42	0.288135593	1	0.288135593	0.288135593	0.288135593	1
3	DS3	JAM	19.48	0.503080082	1	0.503080082	0.503080082	0.503080082	1
4	DS4	JAM	10.59	0.727835052	0.727835052	1	1	0.727835052	0.727835052
5	DS5	GEO	17.41	0.850928683	1	0.850928683	1	1	0.850928683
6	DS6	JAM	18.6	0.84516129	1	0.84516129	0.84516129	0.84516129	1
7	DS17	JAM	6.21	0.791082803	0.791082803	1	0.791082803	0.791082803	0.791082803
8	DS27	GEO	12.24	0.661621622	1	0.661621622	1	1	0.661621622
9	DS40	GEO	28.030001	0.517302871	0.517302871	1	1	1	1
10	DSS1B	GEO	13.1	0.909090909	1	0.909090909	0.909090909	0.909090909	0.909090909
11	DSS1C	JAM	9.88	0.95242915	1	0.95242915	0.95242915	0.95242915	1
12	DSS4	JAM	5.67	0.959435626	1	0.959435626	0.959435626	0.959435626	1
13	SINT-7-9	GEO	12.895	0.642303141	0.642303141	1	0.642303141	0.642303141	1
14	SINT-7-9	GEO	22.985001	0.54067868	0.54067868	1	1	1	1
15	SINT-4-14	GEO	16.658751	0.663277577	0.663277577	1	0.663277577	0.663277577	1
16	SINT-4-14	GEO	20.876251	0.573288949	0.573288949	1	0.573288949	0.573288949	1
17	SINT-15-16	GEO	17.713127	0.636762893	0.636762893	1	0.636762893	0.636762893	1
18	SINT-15-16	JAM	11.738438	0.592196087	0.592196087	1	0.592196087	0.592196087	0.592196087
19	SINT-17-18	JAM	11.393906	0.624655146	0.624655146	1	0.624655146	0.624655146	0.624655146
20	SINT-17-18	JAM	11.623594	0.602424532	0.602424532	1	0.602424532	0.602424532	0.602424532
21	SINT-15-20	JAM	11.19293	0.646327632	0.646327632	1	0.646327632	0.646327632	0.646327632
22	SINT-15-20	GEO	18.635704	0.616023951	0.616023951	1	0.616023951	0.616023951	1
23	SINT-16-22	JAM	11.846104	0.583089069	0.583089069	1	0.583089069	0.583089069	0.583089069
24	SINT-16-22	JAM	11.60206	0.604404881	0.604404881	1	0.604404881	0.604404881	0.604404881
25	SINT-19-24	JAM	11.445944	0.619396178	0.619396178	1	0.619396178	0.619396178	0.619396178
26	SINT-19-24	JAM	11.550022	0.609276098	0.609276098	1	0.609276098	0.609276098	0.609276098
27	SINT-2-12	GEO	6.205	0.34032634	0.34032634	1	0.34032634	0.34032634	0.34032634
28	SINT-2-12	JAM	9.8575	0.577732691	1	0.577732691	0.577732691	0.577732691	1
29	SINT-3-28	JAM	17.074375	0.513854826	1	0.513854826	0.513854826	0.513854826	1
30	SINT-3-28	JAM	12.263124	0.548086279	1	0.548086279	0.548086279	0.548086279	1
31	SINT-8-30	JAM	16.940781	0.641075048	1	0.641075048	1	1	1




Figura A.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura A.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE B

EXPERIMENTO JAM X RN

Tabela B.1: Experimento JAM x RN

Núm. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE RN	Classe Árvore	AE Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	RN	7.15	14.39	7.15	RN	7.15	RN	7.15	RN	7.15
2	DS2	0.03944	0.45466	0.37182	0.1618	RN	20.98	22.42	20.98	RN	20.98	RN	20.98	RN	20.98
3	DS3	0.06978	0.69015	0.39584	0.16805	RN	16.35	19.48	16.35	RN	16.35	JAM	19.48	JAM	19.48
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	10.59	3.54	RN	3.54	RN	3.54	JAM	10.59
5	DS5	0.01651	0.04997	0.13836	0.11496	RN	13.87	20.459999	13.87	RN	13.87	RN	13.87	RN	13.87
6	DS6	0.02785	0.19466	0.00867	0.14702	RN	10.88	18.6	10.88	JAM	18.6	JAM	18.6	JAM	18.6
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	12.33	RN	12.33	JAM	6.21	JAM	6.21
8	DS27	0.03109	0.56245	0.71428	0.06449	RN	11.11	18.5	11.11	RN	11.11	RN	11.11	RN	11.11
9	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	14.5	7.36	RN	7.36	RN	7.36	JAM	14.5
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	RN	12.04	14.41	12.04	RN	12.04	RN	12.04	JAM	14.41
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	RN	5.7	9.88	5.7	RN	5.7	RN	5.7	RN	5.7
12	DSSS4	0.03215	0.089	-0.03236	0.15702	JAM	5.67	5.67	12.54	JAM	5.67	JAM	5.67	RN	12.54
13	SINT-12-7	0.032593	0.1795	-0.01925	0.136077	JAM	5.805	5.805	12.487499	JAM	5.805	JAM	5.805	JAM	5.805
14	SINT-12-7	0.033478	0.3605	0.00697	0.094193	JAM	6.075	6.075	12.3825	JAM	6.075	JAM	6.075	JAM	6.075
15	SINT-14-13	0.033256	0.31525	0.000415	0.104664	JAM	6.0075	6.0075	12.40875	JAM	6.0075	JAM	6.0075	JAM	6.0075
16	SINT-14-13	0.032814	0.22475	-0.012695	0.125606	JAM	5.8725	5.8725	12.461249	JAM	5.8725	JAM	5.8725	JAM	5.8725
17	SINT-12-16	0.032316	0.122938	-0.027444	0.149167	JAM	5.720625	5.720625	12.520312	JAM	5.720625	JAM	5.720625	RN	12.520312
18	SINT-12-16	0.032648	0.190813	-0.017611	0.13346	JAM	5.821876	5.821876	12.480937	JAM	5.821876	JAM	5.821876	JAM	5.821876
19	SINT-15-18	0.033104	0.284141	-0.004092	0.111863	JAM	5.961094	5.961094	12.426796	JAM	5.961094	JAM	5.961094	JAM	5.961094
20	SINT-15-18	0.0328	0.221922	-0.013105	0.126261	JAM	5.868281	5.868281	12.462891	JAM	5.868281	JAM	5.868281	RN	12.462891
21	SINT-18-20	0.032686	0.19859	-0.016485	0.13166	JAM	5.833477	5.833477	12.476425	JAM	5.833477	JAM	5.833477	JAM	5.833477
22	SINT-18-20	0.032762	0.214145	-0.014231	0.12806	JAM	5.85668	5.85668	12.467402	JAM	5.85668	JAM	5.85668	RN	12.467402
23	SINT-19-22	0.033019	0.266642	-0.006627	0.115912	JAM	5.93499	5.93499	12.436948	JAM	5.93499	JAM	5.93499	RN	12.436948
24	SINT-19-22	0.032847	0.231644	-0.011696	0.124011	JAM	5.882783	5.882783	12.457251	JAM	5.882783	JAM	5.882783	RN	12.457251
25	SINT-12-24	0.032324	0.124661	-0.027194	0.148768	JAM	5.723196	5.723196	12.519312	JAM	5.723196	JAM	5.723196	RN	12.519312
26	SINT-12-24	0.032673	0.195983	-0.016862	0.132263	JAM	5.829588	5.829588	12.477938	JAM	5.829588	JAM	5.829588	JAM	5.829588
27	SINT-10-11	0.026013	0.035402	0.13479	0.14575	RN	10.455	13.2775	10.455	RN	10.455	RN	10.455	JAM	13.2775
28	SINT-10-11	0.025818	0.079668	0.16679	0.14343	RN	7.285	11.012501	7.285	RN	7.285	RN	7.285	RN	7.285
29	SINT-27-28	0.025964	0.046469	0.14279	0.14517	RN	9.6625	12.71125	9.6625	RN	9.6625	RN	9.6625	RN	9.6625
30	SINT-27-28	0.025866	0.068601	0.15879	0.14401	RN	8.077499	11.578751	8.077499	RN	8.077499	RN	8.077499	RN	8.077499
31	SINT-9-30	0.028397	0.179	0.304215	0.144303	RN	7.539375	13.769688	7.539375	RN	7.539375	RN	7.539375	JAM	13.769688

Tabela B.2: Experimento JAM x RN - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo	AE Modelo	AE Ótimo	AE JAM	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	RN	7.15	0.496872828	1	0.496872828	0.496872828	0.496872828	0.496872828
2	DS2	RN	20.98	0.935771632	1	0.935771632	0.935771632	0.935771632	0.935771632
3	DS3	JAM	19.48	0.839322382	1	0.839322382	0.839322382	1	1
4	DS4	JAM	10.59	0.33427762	1	0.33427762	0.33427762	0.33427762	1
5	DS5	RN	13.87	0.677908147	1	0.677908147	0.677908147	0.677908147	0.677908147
6	DS6	JAM	18.6	0.584946237	1	0.584946237	1	1	1
7	DS17	JAM	6.21	0.503649635	0.503649635	1	1	0.503649635	0.503649635
8	DS27	RN	11.11	0.600540541	1	0.600540541	0.600540541	0.600540541	0.600540541
9	DS40	JAM	14.5	0.507586207	1	0.507586207	0.507586207	1	1
10	DS40	JAM	14.41	0.835530881	1	0.835530881	0.835530881	0.835530881	1
11	DSS1B	JAM	5.7	0.576923077	1	0.576923077	0.576923077	0.576923077	0.576923077
12	DSS1C	RN	12.54	0.45215311	0.45215311	1	0.45215311	0.45215311	1
13	SINT-12-7	JAM	5.805	0.464864902	0.464864902	1	0.464864902	0.464864902	0.464864902
14	SINT-12-7	JAM	6.075	0.49061175	0.49061175	1	0.49061175	0.49061175	0.49061175
15	SINT-14-13	JAM	6.0075	0.48413418	0.48413418	1	0.48413418	0.48413418	0.48413418
16	SINT-14-13	JAM	5.8725	0.471260947	0.471260947	1	0.471260947	0.471260947	0.471260947
17	SINT-12-16	RN	12.520312	0.456907544	0.456907544	1	0.456907544	0.456907544	1
18	SINT-12-16	JAM	5.821876	0.466461452	0.466461452	1	0.466461452	0.466461452	0.466461452
19	SINT-15-18	JAM	5.961094	0.479696778	0.479696778	1	0.479696778	0.479696778	0.479696778
20	SINT-15-18	RN	12.462891	0.470860332	0.470860332	1	0.470860332	0.470860332	1
21	SINT-18-20	JAM	5.833477	0.467559978	0.467559978	1	0.467559978	0.467559978	0.467559978
22	SINT-18-20	RN	12.467402	0.469759458	0.469759458	1	0.469759458	0.469759458	1
23	SINT-19-22	RN	12.436948	0.477206305	0.477206305	1	0.477206305	0.477206305	1
24	SINT-19-22	RN	12.457251	0.47237655	0.47237655	1	0.47237655	0.47237655	1
25	SINT-12-24	RN	12.519312	0.457149402	0.457149402	1	0.457149402	0.457149402	1
26	SINT-12-24	JAM	5.829588	0.467191615	0.467191615	1	0.467191615	0.467191615	0.467191615
27	SINT-10-11	JAM	13.2775	0.787422331	0.787422331	1	0.787422331	0.787422331	1
28	SINT-10-11	RN	7.285	0.661520939	0.661520939	1	0.661520939	0.661520939	0.661520939
29	SINT-27-28	RN	9.6625	0.760153407	0.760153407	1	0.760153407	0.760153407	0.760153407
30	SINT-27-28	RN	8.077499	0.697614017	0.697614017	1	0.697614017	0.697614017	0.697614017
31	SINT-9-30	JAM	13.769688	0.547534192	0.547534192	1	0.547534192	0.547534192	1




Figura B.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura B.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE C

EXPERIMENTO JAM X GEO X RN

Tabela C.1: Experimento JAM x GEO x RN

Num. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE GEO	AE RN	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	RN	7.15	14.39	7.69	7.15	RN	7.15	RN	7.15	JAM	14.39
2	DS2	0.03944	0.45466	0.37182	0.1618	GEO	6.46	22.42	6.46	20.98	GEO	6.46	GEO	20.98	GEO	6.46
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	19.48	9.8	16.35	GEO	9.8	GEO	9.8	JAM	19.48
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	10.59	14.55	13.87	JAM	10.59	JAM	10.59	RN	3.54
5	DS5	0.01651	0.04997	0.13836	0.11496	RN	13.87	20.459999	17.41	13.87	RN	13.87	GEO	13.87	JAM	20.459999
6	DS6	0.02785	0.19466	0.00867	0.14702	RN	10.88	18.6	15.72	10.88	GEO	15.72	GEO	15.72	JAM	18.6
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	7.85	12.33	JAM	6.21	JAM	6.21	JAM	6.21
8	DS7	0.03109	0.56245	0.71428	0.06449	RN	11.11	18.5	12.24	11.11	JAM	18.5	RN	11.11	RN	11.11
9	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	14.5	28.030001	7.36	RN	7.36	RN	7.36	GEO	28.030001
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	RN	12.04	14.41	13.1	12.04	RN	12.04	RN	12.04	RN	12.04
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	RN	5.7	9.88	9.41	5.7	RN	5.7	RN	5.7	GEO	9.41
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	6.075	5.44	12.54	JAM	5.67	RN	12.54	RN	12.54
13	SINT-7-12	0.033478	0.3605	0.00697	0.094193	JAM	6.075	6.075	7.2475	12.3825	JAM	6.075	JAM	6.075	JAM	6.075
14	SINT-7-13	0.033809	0.428375	0.016803	0.078486	JAM	6.17625	6.17625	7.699375	12.343124	JAM	6.17625	JAM	6.17625	RN	12.343124
15	SINT-7-13	0.033588	0.383125	0.010248	0.088957	JAM	6.10875	6.10875	7.398125	12.369375	JAM	6.10875	JAM	6.10875	GEO	7.398125
16	SINT-7-15	0.033837	0.434031	0.017622	0.077177	JAM	6.184688	6.184688	7.737031	12.339844	JAM	6.184688	JAM	6.184688	GEO	7.737031
17	SINT-7-15	0.033671	0.400094	0.012706	0.08503	JAM	6.134063	6.134063	7.511094	12.359531	JAM	6.134063	JAM	6.134063	RN	12.359531
18	SINT-13-17	0.033526	0.370398	0.008404	0.091902	JAM	6.089766	6.089766	7.313398	12.376758	JAM	6.089766	JAM	6.089766	JAM	6.089766
19	SINT-13-17	0.033623	0.390195	0.011272	0.087321	JAM	6.119297	6.119297	7.445195	12.365273	JAM	6.119297	JAM	6.119297	RN	12.365273
20	SINT-12-3	0.041557	0.239287	0.07469	0.159778	GEO	6.53	9.122499	6.53	13.4925	GEO	6.53	GEO	6.53	JAM	9.122499
21	SINT-12-3	0.060373	0.539863	0.28879	0.165293	GEO	8.71	16.0275	8.71	15.3975	GEO	8.71	GEO	8.71	JAM	16.0275
22	SINT-21-20	0.055669	0.464719	0.235265	0.163914	GEO	8.165	14.30125	8.165	14.921249	GEO	8.165	GEO	8.165	JAM	14.30125
23	SINT-21-20	0.046261	0.314431	0.128215	0.161156	GEO	7.075	10.848749	7.075	13.96875	GEO	7.075	GEO	7.075	JAM	10.848749
24	SINT-22-23	0.053317	0.427147	0.208502	0.163224	GEO	7.8925	13.438126	7.8925	14.683125	GEO	7.8925	GEO	7.8925	RN	14.683125
25	SINT-22-23	0.048613	0.352003	0.154977	0.161846	GEO	7.3475	11.711874	7.3475	14.206875	GEO	7.3475	GEO	7.3475	GEO	7.3475
26	SINT-13-19	0.033514	0.367924	0.008045	0.092475	JAM	6.086074	6.086074	7.296924	12.378193	JAM	6.086074	JAM	6.086074	RN	12.378193
27	SINT-13-19	0.033586	0.382771	0.010196	0.089039	JAM	6.108223	6.108223	7.395772	12.369579	JAM	6.108223	JAM	6.108223	RN	12.369579
28	SINT-18-27	0.033541	0.373492	0.008852	0.091186	JAM	6.09438	6.09438	7.333992	12.374964	JAM	6.09438	JAM	6.09438	RN	12.374964
29	SINT-18-27	0.033571	0.379678	0.009748	0.089754	JAM	6.103609	6.103609	7.375178	12.371374	JAM	6.103609	JAM	6.103609	JAM	6.103609
30	SINT-21-25	0.057453	0.492898	0.255337	0.164431	GEO	8.369375	14.948593	8.369375	15.099844	GEO	8.369375	GEO	8.369375	GEO	8.369375
31	SINT-21-25	0.051553	0.398968	0.188431	0.162707	GEO	7.688125	12.790781	7.688125	14.504531	GEO	7.688125	GEO	7.688125	JAM	12.790781

Tabela C.2: Experimento JAM x GEO x RN - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE JAM	AE GEO	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	JAM	14.39	0.496872828	1	0.534398888	0.496872828	0.496872828	0.496872828	1
2	DS2	GEO	6.46	0.288135593	1	0.288135593	0.935771632	0.288135593	0.935771632	0.288135593
3	DS3	JAM	19.48	0.503080082	1	0.503080082	0.839323282	0.503080082	0.503080082	1
4	DS4	RN	3.54	0.243298969	0.727835052	1	0.243298969	0.727835052	0.727835052	0.243298969
5	DS5	JAM	20.459999	0.677908147	1	0.850928683	0.677908147	0.677908147	0.677908147	1
6	DS6	JAM	18.6	0.584946237	1	0.84516129	0.584946237	0.84516129	0.84516129	1
7	DS17	JAM	6.21	0.503649635	0.503649635	0.636658556	0.584946237	0.503649635	0.503649635	0.503649635
8	DS27	RN	11.11	0.600540541	1	0.661621622	0.584946237	0.600540541	0.600540541	0.600540541
9	DS40	GEO	28.030001	0.262575802	0.517302871	1	0.600540541	1	0.262575802	1
10	DSS1B	RN	12.04	0.835530881	1	0.909090909	0.835530881	0.835530881	0.835530881	0.835530881
11	DSS1C	GEO	9.41	0.576923077	1	0.95242915	0.576923077	0.576923077	0.576923077	0.95242915
12	DSS4	RN	12.54	0.433811802	0.45215311	0.433811802	1	0.45215311	1	1
13	SINT-7-12	JAM	6.075	0.49061175	0.49061175	0.585301837	1	0.49061175	0.49061175	0.49061175
14	SINT-7-13	RN	12.343124	0.500379807	0.500379807	0.62377847	1	0.500379807	0.500379807	1
15	SINT-7-13	GEO	7.398125	0.493860846	0.493860846	0.598100147	1	0.493860846	0.493860846	0.598100147
16	SINT-7-15	GEO	7.737031	0.501196612	0.501196612	0.626995852	1	0.501196612	0.501196612	0.626995852
17	SINT-7-15	RN	12.359531	0.496302246	0.496302246	0.607716749	1	0.496302246	0.496302246	1
18	SINT-13-17	JAM	6.089766	0.492032405	0.492032405	0.590897713	1	0.492032405	0.492032405	0.492032405
19	SINT-13-17	RN	12.365273	0.49487763	0.49487763	0.602105186	1	0.49487763	0.49487763	1
20	SINT-12-3	JAM	9.122499	0.483972577	0.676116287	0.483972577	1	0.483972577	0.483972577	0.676116287
21	SINT-12-3	JAM	16.0275	0.543440961	1	0.543440961	0.960609256	0.543440961	0.543440961	1
22	SINT-21-20	JAM	14.30125	0.547206202	0.958448586	0.547206202	1	0.547206202	0.547206202	0.958448586
23	SINT-21-20	JAM	10.848749	0.506487696	0.7776644224	0.506487696	1	0.506487696	0.506487696	0.7776644224
24	SINT-22-23	RN	14.683125	0.537521815	0.915208854	0.537521815	1	0.537521815	0.537521815	1
25	SINT-22-23	GEO	7.3475	0.517179183	0.824380731	0.517179183	1	0.517179183	0.517179183	0.517179183
26	SINT-13-19	RN	12.378193	0.491677097	0.491677097	0.589498322	1	0.491677097	0.491677097	1
27	SINT-13-19	RN	12.369579	0.493810097	0.493810097	0.597900058	1	0.493810097	0.493810097	1
28	SINT-18-27	RN	12.374964	0.492476584	0.492476584	0.592647542	1	0.492476584	0.492476584	1
29	SINT-18-27	JAM	6.103609	0.49336549	0.49336549	0.596148657	1	0.49336549	0.49336549	0.49336549
30	SINT-21-25	GEO	8.369375	0.554268971	0.989983274	0.554268971	1	0.554268971	0.554268971	0.554268971
31	SINT-21-25	JAM	12.790781	0.530049886	0.881847266	0.530049886	1	0.530049886	0.530049886	0.881847266




Figura C.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura C.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE D

EXPERIMENTO JAM X GEO X PG2

Tabela D.1: Experimento JAM x GEO x PG2

Núm. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE GEO	AE PG2	Classe Árvore	Árvore	Classe Rede Neural	AE Rede	Modelo Aleat.	AE Modelo
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	14.39	7.69	4.55	JAM	14.39	JAM	14.39	JAM	14.39
2	DS2	0.03944	0.45466	0.1618	0.1618	GEO	6.46	22.42	6.46	7.21	GEO	6.46	JAM	22.42	PG2	7.21
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	19.48	9.8	11.234	GEO	9.8	GEO	9.8	JAM	19.48
4	DS4	0.03793	0.70296	0.43633	0.05507	JAM	10.59	10.59	14.55	21.440001	JAM	10.59	JAM	10.59	PG2	21.440001
5	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	20.459999	17.41	10.54	PG2	10.54	PG2	10.54	GEO	17.41
6	DS6	0.02785	0.19466	0.00867	0.14702	PG2	11.23	18.6	15.72	11.23	GEO	15.72	GEO	15.72	PG2	11.23
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	7.85	14.24	JAM	6.21	JAM	6.21	PG2	14.24
8	DS7	0.03109	0.56245	0.71428	0.06449	GEO	12.24	18.5	12.24	14.066	JAM	18.5	JAM	18.5	JAM	18.5
9	DS40	0.02924	0.2158	0.35269	0.1444	JAM	14.5	14.5	28.030001	57.400002	GEO	28.030001	GEO	28.030001	PG2	57.400002
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	GEO	13.1	14.41	13.1	19.74	GEO	13.1	GEO	13.1	JAM	14.41
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	GEO	9.41	9.88	9.41	16.65	PG2	16.65	PG2	16.65	JAM	9.88
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.67	5.44	27.85	GEO	5.44	GEO	5.44	PG2	27.85
13	SINT-7-9	0.03275	0.3922	0.103233	0.091037	JAM	8.282499	8.282499	12.895	25.029999	JAM	8.282499	JAM	8.282499	PG2	25.029999
14	SINT-7-9	0.03041	0.2746	0.269538	0.126612	JAM	12.4275	12.4275	22.985001	46.610001	JAM	12.4275	PG2	46.610001	JAM	12.4275
15	SINT-14-13	0.03095	0.304	0.227961	0.117719	JAM	11.39125	11.39125	20.462502	41.215	JAM	11.39125	JAM	11.39125	PG2	41.215
16	SINT-14-13	0.032165	0.3628	0.144809	0.099931	JAM	9.318749	9.318749	15.4175	30.424999	JAM	9.318749	JAM	9.318749	PG2	30.424999
17	SINT-1-6	0.028555	0.317248	0.25017	0.13727	PG2	6.22	15.442501	9.6975	6.22	PG2	6.22	PG2	6.22	PG2	6.22
18	SINT-1-6	0.028085	0.235523	0.08917	0.14377	PG2	9.559999	17.547501	13.7125	9.559999	GEO	13.7125	PG2	9.559999	PG2	9.559999
19	SINT-5-18	0.019404	0.096358	0.126062	0.121162	PG2	10.295	19.731874	16.485624	10.295	GEO	16.485624	PG2	10.295	PG2	10.295
20	SINT-5-18	0.025191	0.189134	0.101468	0.136568	PG2	9.804999	18.275625	14.636875	9.804999	PG2	9.804999	PG2	9.804999	PG2	9.804999
21	SINT-7-16	0.033481	0.42895	0.051262	0.07992	JAM	6.987187	6.987187	9.741875	18.286251	JAM	6.987187	JAM	6.987187	PG2	18.286251
22	SINT-7-16	0.032604	0.38485	0.113627	0.093261	JAM	8.541562	8.541562	13.525625	26.37875	JAM	8.541562	JAM	8.541562	GEO	13.525625
23	SINT-13-22	0.032713	0.390363	0.105831	0.091593	JAM	8.347265	8.347265	13.052656	25.367188	JAM	8.347265	JAM	8.347265	JAM	8.347265
24	SINT-13-22	0.03264	0.386688	0.111028	0.092705	JAM	8.476797	8.476797	13.36797	26.041561	JAM	8.476797	JAM	8.476797	PG2	26.041561
25	SINT-12-11	0.030543	0.0922	0.021427	0.153333	GEO	6.4325	6.7225	6.4325	25.049999	GEO	6.4325	GEO	6.4325	PG2	25.049999
26	SINT-12-11	0.027328	0.0986	0.129002	0.145957	GEO	8.4175	8.8275	8.4175	19.450001	PG2	19.450001	GEO	8.4175	JAM	8.8275
27	SINT-3-26	0.059167	0.542263	0.329131	0.162527	GEO	9.454374	16.810875	9.454374	13.288	GEO	9.454374	GEO	9.454374	JAM	9.454374
28	SINT-3-26	0.037941	0.246488	0.195712	0.151481	GEO	8.763124	11.490625	8.763124	17.396	GEO	8.763124	GEO	8.763124	GEO	8.763124
29	SINT-17-20	0.027714	0.285219	0.212994	0.137094	PG2	7.11625	16.150782	10.932344	7.11625	PG2	7.11625	PG2	7.11625	PG2	7.11625
30	SINT-17-20	0.026032	0.221163	0.138643	0.136743	PG2	8.90875	17.567345	13.402031	8.90875	PG2	8.90875	PG2	8.90875	JAM	17.567345
31	SINT-5-30	0.018891	0.092768	0.138431	0.120406	PG2	10.132187	19.736835	16.408009	10.132187	PG2	10.132187	PG2	10.132187	GEO	16.408009

Tabela D.2: Experimento JAM x GEO x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE JAM	AE GEO	AE PG2	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	JAM	14.39	0.3161918	1	0.534398888	0.3161918	1	1	1
2	DS2	PG2	7.21	0.288135593	1	0.288135593	0.321587868	0.288135593	1	0.321587868
3	DS3	JAM	19.48	0.503080082	1	0.503080082	0.576694045	0.503080082	0.503080082	1
4	DS4	PG2	21.440001	0.493936544	0.493936544	0.678638028	1	0.493936544	0.493936544	1
5	DS5	GEO	17.41	0.51515154	1	0.850928683	0.51515154	0.51515154	0.51515154	0.850928683
6	DS6	PG2	11.23	0.603763441	1	0.84516129	0.603763441	0.84516129	0.84516129	0.603763441
7	DS17	PG2	14.24	0.436095506	1	0.551264045	1	0.436095506	0.436095506	1
8	DS27	JAM	18.5	0.661621622	1	0.661621622	0.760324324	1	1	1
9	DS40	PG2	57.400002	0.252613232	1	0.488327527	1	0.488327527	0.488327527	1
10	DSS1B	JAM	14.41	0.663627153	0.729989868	0.663627153	1	0.663627153	0.663627153	0.729989868
11	DSS1C	JAM	9.88	0.565165165	0.593393393	0.565165165	1	1	1	0.593393393
12	DSS4	PG2	27.85	0.195332136	0.203590664	0.195332136	1	0.195332136	0.195332136	1
13	SINT-7-9	PG2	25.029999	0.33090289	0.33090289	0.515181802	1	0.33090289	0.33090289	1
14	SINT-7-9	JAM	12.4275	0.266627327	0.266627327	0.493134531	1	0.266627327	1	0.266627327
15	SINT-14-13	PG2	41.215	0.276386025	0.276386025	0.496481912	1	0.276386025	0.276386025	1
16	SINT-14-13	PG2	30.424999	0.306285926	0.306285926	0.506737897	1	0.306285926	0.306285926	1
17	SINT-1-6	PG2	6.22	0.402784497	1	0.627974704	0.402784497	0.402784497	0.402784497	0.402784497
18	SINT-1-6	PG2	9.559999	0.544806865	1	0.781450305	0.544806865	0.781450305	0.544806865	0.544806865
19	SINT-5-18	PG2	10.295	0.521744666	1	0.835481921	0.521744666	0.835481921	0.521744666	0.521744666
20	SINT-5-18	PG2	9.804999	0.536506905	1	0.800896002	0.536506905	0.536506905	0.536506905	0.536506905
21	SINT-7-16	PG2	18.286251	0.382100574	0.382100574	0.532743152	1	0.382100574	0.382100574	1
22	SINT-7-16	GEO	13.525625	0.323804653	0.323804653	0.512747003	1	0.323804653	0.323804653	0.512747003
23	SINT-13-22	JAM	8.347265	0.32905756	0.32905756	0.514548794	1	0.32905756	0.32905756	0.32905756
24	SINT-13-22	PG2	26.041561	0.325510326	0.325510326	0.513332131	1	0.325510326	0.325510326	1
25	SINT-12-11	GEO	6.4325	0.256786437	0.268363284	0.256786437	1	0.256786437	0.256786437	0.256786437
26	SINT-12-11	JAM	8.8275	0.432776327	0.453856018	0.432776327	1	1	0.432776327	0.432776327
27	SINT-3-26	GEO	9.454374	0.562195652	1	0.562195652	0.790158695	0.562195652	0.562195652	0.562195652
28	SINT-3-26	GEO	8.763124	0.503743619	0.660532594	0.503743619	1	0.503743619	0.503743619	0.503743619
29	SINT-17-20	PG2	7.11625	0.44061334	1	0.676892549	0.44061334	0.44061334	0.44061334	0.44061334
30	SINT-17-20	JAM	17.567345	0.507119886	1	0.762894507	0.507119886	0.507119886	0.507119886	1
31	SINT-5-30	GEO	16.408009	0.513364326	1	0.831339422	0.513364326	0.513364326	0.513364326	0.831339422




Figura D.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura D.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE E

EXPERIMENTO JAM X RN X PG2

Tabela E.1: Experimento JAM x RN x PG2

Núm. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE PG2	AE RN	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	14.39	4.55	7.15	RN	7.15	RN	7.15	PG2	4.55
2	DS2	0.03944	0.45466	0.37182	0.1618	PG2	7.21	22.42	7.21	20.98	PG2	7.21	RN	20.98	JAM	22.42
3	DS3	0.06978	0.69015	0.39584	0.16805	PG2	11.234	19.48	11.234	16.35	PG2	11.234	PG2	11.234	PG2	11.234
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	10.59	21.440001	3.54	PG2	21.440001	PG2	21.440001	JAM	10.59
5	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	20.459999	10.54	13.87	RN	13.87	RN	13.87	PG2	10.54
6	DS6	0.02785	0.19466	0.00867	0.14702	RN	10.88	18.6	11.23	10.88	JAM	18.6	RN	10.88	RN	10.88
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	14.24	14.24	12.33	PG2	12.33	JAM	6.21	RN	12.33
8	DS27	0.03109	0.56245	0.71428	0.06449	RN	11.11	18.5	14.066	11.11	PG2	14.066	JAM	18.5	PG2	14.066
9	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	14.5	57.400002	7.36	RN	7.36	RN	7.36	JAM	14.5
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	RN	12.04	14.41	19.74	12.04	RN	12.04	PG2	19.74	RN	12.04
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	RN	5.7	9.88	16.65	5.7	RN	5.7	RN	5.7	RN	5.7
12	DSSS4	0.03215	0.089	-0.03236	0.15702	JAM	5.67	5.67	27.85	12.54	JAM	5.67	JAM	5.67	RN	12.54
13	SINT-12-7	0.032593	0.1795	-0.01925	0.136077	JAM	5.805	5.805	24.4475	12.487499	JAM	5.805	JAM	5.805	PG2	24.4475
14	SINT-12-7	0.033478	0.3605	0.00697	0.094193	JAM	6.075	6.075	17.6425	12.3825	JAM	6.075	JAM	6.075	PG2	17.6425
15	SINT-12-14	0.032482	0.156875	-0.022527	0.141313	JAM	5.77125	5.77125	25.298126	12.500626	JAM	5.77125	JAM	5.77125	RN	12.500626
16	SINT-12-14	0.033146	0.292625	-0.002862	0.109899	JAM	5.97375	5.97375	20.194374	12.421875	JAM	5.97375	JAM	5.97375	JAM	5.97375
17	SINT-3-5	0.056463	0.530105	0.33147	0.154777	PG2	11.0605	19.724998	11.0605	15.73	PG2	11.0605	PG2	11.0605	JAM	19.724998
18	SINT-3-5	0.029828	0.210015	0.20273	0.128233	PG2	10.7135	20.215	10.7135	14.49	RN	14.49	RN	14.49	PG2	10.7135
19	SINT-13-16	0.032731	0.207781	-0.015153	0.129533	JAM	5.847188	5.847188	23.38422	12.471093	JAM	5.847188	JAM	5.847188	PG2	23.38422
20	SINT-13-16	0.033007	0.264344	-0.006959	0.116444	JAM	5.931562	5.931562	21.257656	12.438281	JAM	5.931562	JAM	5.931562	JAM	5.931562
21	SINT-20-19	0.032938	0.250203	-0.009008	0.119716	JAM	5.910469	5.910469	21.789297	12.446484	JAM	5.910469	JAM	5.910469	RN	12.446484
22	SINT-20-19	0.0328	0.221922	-0.013105	0.126261	JAM	5.868281	5.868281	22.852579	12.462891	JAM	5.868281	JAM	5.868281	JAM	5.868281
23	SINT-20-22	0.032955	0.253738	-0.008496	0.118898	JAM	5.915742	5.915742	21.656387	12.444433	JAM	5.915742	JAM	5.915742	RN	12.444433
24	SINT-20-22	0.032852	0.232527	-0.011568	0.123806	JAM	5.884102	5.884102	22.45385	12.456738	JAM	5.884102	JAM	5.884102	PG2	22.45385
25	SINT-9-11	0.02836	0.1873	0.310215	0.143867	RN	6.945	13.345	47.212502	6.945	RN	6.945	RN	6.945	JAM	13.345
26	SINT-9-11	0.0266	0.1303	0.225265	0.142803	RN	6.115	11.035	26.837502	6.115	RN	6.115	RN	6.115	JAM	11.035
27	SINT-6-26	0.027537	0.17857	0.062819	0.145966	RN	9.688749	16.70875	15.131875	9.688749	RN	9.688749	RN	9.688749	JAM	16.70875
28	SINT-6-26	0.026912	0.14639	0.171116	0.143857	RN	7.30625	12.92625	22.935627	7.30625	RN	7.30625	RN	7.30625	RN	7.30625
29	SINT-26-28	0.026678	0.134322	0.211728	0.143066	RN	6.412812	11.507813	25.862034	6.412812	RN	6.412812	RN	6.412812	JAM	11.507813
30	SINT-26-28	0.026834	0.142367	0.184653	0.143593	RN	7.008437	12.453438	23.911095	7.008437	RN	7.008437	RN	7.008437	JAM	12.453438
31	SINT-3-18	0.059792	0.570116	0.347562	0.158096	PG2	11.103875	19.66375	11.103875	15.885	PG2	11.103875	PG2	11.103875	PG2	11.103875

Tabela E.2: Experimento JAM x RN x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE JAM	AE PG2	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	PG2	4.55	0.3161918	1	0.3161918	0.496872828	0.496872828	0.496872828	0.3161918
2	DS2	JAM	22.42	0.321587868	1	0.321587868	0.83932382	0.321587868	0.935771632	1
3	DS3	PG2	11.234	0.576694045	1	0.576694045	0.83932382	0.576694045	0.576694045	0.576694045
4	DS4	JAM	10.59	0.165111933	0.493936544	1	0.165111933	1	1	1
5	DS5	PG2	10.54	0.51515154	1	0.51515154	0.677908147	0.677908147	0.677908147	0.51515154
6	DS6	RN	10.88	0.584946237	1	0.603763441	0.584946237	1	0.584946237	0.584946237
7	DS17	RN	12.33	0.436095506	0.436095506	1	0.865870787	0.865870787	0.865870787	0.760324324
8	DS27	PG2	14.066	0.600540541	1	0.760324324	0.600540541	0.760324324	0.436095506	1
9	DS40	JAM	14.5	0.128222992	0.252613232	1	0.128222992	0.128222992	0.128222992	0.252613232
10	DSS1B	RN	12.04	0.609929078	0.729989868	1	0.609929078	0.609929078	1	0.609929078
11	DSS1C	RN	5.7	0.342342342	0.342342342	1	0.342342342	0.342342342	0.342342342	0.342342342
12	DSS4	RN	12.54	0.203590664	0.593393393	1	0.203590664	0.203590664	0.203590664	0.4502693
13	SINT-12-7	PG2	24.4475	0.237447592	0.203590664	1	0.510788383	0.237447592	0.237447592	1
14	SINT-12-7	PG2	17.6425	0.344338954	0.344338954	1	0.701856313	0.344338954	0.344338954	1
15	SINT-12-14	RN	12.500626	0.228129546	0.228129546	1	0.49413249	0.228129546	0.228129546	0.49413249
16	SINT-12-14	JAM	5.97375	0.295812586	0.295812586	1	0.615115626	0.295812586	0.295812586	0.295812586
17	SINT-3-5	JAM	19.724998	0.560735165	1	0.560735165	0.797465227	0.560735165	1	1
18	SINT-3-5	PG2	10.7135	0.529977739	1	0.529977739	0.71679446	0.71679446	0.529977739	0.529977739
19	SINT-13-16	PG2	23.38422	0.250048451	0.250048451	1	0.533312336	0.250048451	0.250048451	1
20	SINT-13-16	JAM	5.931562	0.279031799	0.279031799	1	0.585120062	0.279031799	0.279031799	0.279031799
21	SINT-20-19	RN	12.446484	0.271255608	0.271255608	1	0.571220081	0.271255608	0.271255608	0.571220081
22	SINT-20-19	JAM	5.868281	0.256788566	0.256788566	1	0.545360373	0.256788566	0.256788566	0.256788566
23	SINT-20-22	RN	12.444433	0.273163848	0.273163848	1	0.574631078	0.273163848	0.273163848	1
24	SINT-20-22	PG2	22.45385	0.262053145	0.262053145	1	0.554770696	0.262053145	0.262053145	1
25	SINT-9-11	JAM	13.345	0.147100867	0.282658182	1	0.147100867	0.147100867	0.147100867	1
26	SINT-9-11	JAM	11.035	0.227852801	0.411178358	1	0.227852801	0.227852801	0.227852801	0.411178358
27	SINT-6-26	JAM	16.70875	0.579860792	1	0.9056625795	0.579860792	0.579860792	0.579860792	1
28	SINT-6-26	RN	7.30625	0.318554622	0.563588255	1	0.318554622	0.318554622	0.318554622	0.318554622
29	SINT-26-28	JAM	11.507813	0.247962399	0.444969371	1	0.247962399	0.247962399	0.247962399	0.444969371
30	SINT-26-28	JAM	12.453438	0.293103975	0.520822572	1	0.293103975	0.293103975	0.293103975	0.520822572
31	SINT-3-18	PG2	11.103875	0.56468756	1	0.56468756	0.80783167	0.56468756	0.56468756	0.56468756




Figura E.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura E.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE F

EXPERIMENTO JAM X GEO X RN X PG2

Tabela F.1: Experimento JAM x GEO x RN x PG2

Num Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE GEO	AE PG2	AE Árvore	Classe Árvore	AE Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	14.39	7.69	4.55	7.15	RN	7.15	PG2	4.55	PG2	4.55
2	DS2	0.03944	0.45466	0.37182	0.1618	GEO	6.46	22.42	6.46	7.21	20.98	GEO	6.46	GEO	6.46	RN	20.98
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	19.48	9.8	11.234	16.35	GEO	9.8	GEO	9.8	RN	16.35
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	10.59	14.55	21.440001	3.54	JAM	10.59	JAM	10.59	JAM	10.59
5	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	20.459999	17.41	10.54	13.87	PG2	10.54	PG2	10.54	JAM	20.459999
6	DS6	0.02785	0.19466	0.00867	0.14702	RN	18.6	6.21	15.72	11.23	10.88	GEO	15.72	RN	10.88	RN	10.88
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	7.85	14.24	12.33	JAM	6.21	JAM	6.21	RN	12.33
8	DS27	0.03109	0.56245	0.71428	0.06449	RN	11.11	18.5	12.24	14.066	11.11	JAM	18.5	PG2	14.066	PG2	14.066
9	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	14.5	28.030001	57.400002	7.36	RN	7.36	PG2	57.400002	PG2	57.400002
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	RN	12.04	14.41	13.1	19.74	12.04	RN	12.04	RN	12.04	PG2	19.74
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	RN	5.7	9.88	9.41	16.65	16.65	PG2	5.7	RN	5.7	RN	5.7
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.67	5.44	27.85	12.54	GEO	5.44	RN	12.54	PG2	27.85
13	SINT-7-12	0.033478	0.3605	0.00697	0.094193	JAM	6.075	6.075	7.2475	17.6425	6.075	JAM	6.075	JAM	6.075	GEO	7.2475
14	SINT-13-7	0.033588	0.383125	0.010248	0.088957	JAM	6.10875	6.10875	7.398125	16.791874	6.10875	JAM	6.10875	JAM	6.10875	RN	12.369375
15	SINT-13-7	0.033809	0.428375	0.016803	0.078486	JAM	6.17625	6.17625	7.699375	15.090625	6.17625	JAM	6.17625	JAM	6.17625	PG2	15.090625
16	SINT-15-14	0.033754	0.417063	0.015164	0.081103	JAM	6.159375	6.159375	7.624063	15.515938	6.159375	JAM	6.159375	JAM	6.159375	PG2	15.515938
17	SINT-15-14	0.033643	0.394437	0.011886	0.086339	JAM	6.125625	6.125625	7.473437	16.366562	6.125625	JAM	6.125625	JAM	6.125625	JAM	18.869999
18	SINT-2-12	0.037617	0.363245	0.270775	0.160605	GEO	6.205	18.2325	6.205	12.370001	6.205	GEO	6.205	GEO	6.205	RN	18.869999
19	SINT-2-12	0.033973	0.180415	0.068685	0.158215	GEO	5.695	9.8375	5.695	22.690001	5.695	GEO	5.695	GEO	5.695	RN	14.65
20	SINT-3-19	0.060828	0.562716	0.314051	0.165591	GEO	8.77375	17.074375	8.77375	14.098	15.925	GEO	8.77375	GEO	8.77375	PG2	14.098
21	SINT-3-19	0.042924	0.307849	0.150474	0.160674	GEO	6.72125	12.263124	6.72125	19.826	15.075	GEO	6.72125	GEO	6.72125	RN	15.075
22	SINT-1-5	0.02572	0.281075	0.282593	0.129255	PG2	6.0475	15.907499	10.12	6.0475	8.83	PG2	6.0475	PG2	6.0475	RN	8.83
23	SINT-1-5	0.01958	0.127005	0.186437	0.119725	PG2	9.0425	18.942499	14.98	9.0425	12.190001	PG2	9.0425	PG2	9.0425	RN	12.190001
24	SINT-22-23	0.024185	0.242557	0.258554	0.129725	PG2	6.79625	16.666248	11.334999	6.79625	9.67	PG2	6.79625	PG2	6.79625	JAM	16.666248
25	SINT-22-23	0.021115	0.165523	0.210476	0.122108	PG2	8.29375	18.18375	13.764999	8.29375	11.35	PG2	8.29375	PG2	8.29375	PG2	8.29375
26	SINT-13-17	0.033519	0.368984	0.008199	0.092229	JAM	6.087656	6.087656	7.303985	17.325517	6.087656	JAM	6.087656	JAM	6.087656	PG2	17.325517
27	SINT-13-17	0.033602	0.385953	0.010657	0.088302	JAM	6.112968	6.112968	7.416953	16.685547	12.367734	JAM	6.112968	JAM	6.112968	GEO	7.416953
28	SINT-2-21	0.040311	0.417957	0.316483	0.161518	GEO	6.525312	19.880781	6.525312	10.364	19.50375	GEO	6.525312	GEO	6.525312	RN	19.50375
29	SINT-2-21	0.042053	0.344552	0.20581	0.160955	GEO	6.655937	14.802343	6.655937	16.672001	16.5125	GEO	6.655937	GEO	6.655937	RN	16.5125
30	SINT-6-11	0.027318	0.171445	0.0522	0.145833	RN	9.585	16.42	14.1425	12.584999	9.585	RN	9.585	RN	9.585	GEO	14.1425
31	SINT-6-11	0.026253	0.125015	0.13926	0.143458	RN	6.995	12.059999	10.9875	15.295	6.995	RN	6.995	RN	6.995	RN	6.995

Tabela F.2: Experimento JAM x GEO x RN x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE JAM	AE GEO	AE PG2	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	PG2	4.55	0.3161918	1	0.534398888	0.3161918	0.496872828	0.496872828	0.3161918	0.3161918
2	DS2	RN	20.98	0.288135593	1	0.288135593	0.321587868	0.935771632	0.288135593	0.288135593	0.935771632
3	DS3	RN	16.35	0.503080082	1	0.503080082	0.576694045	0.839322382	0.503080082	0.503080082	0.839322382
4	DS4	JAM	10.59	0.165111933	0.493936544	0.78638028	0.51515154	0.165111933	0.493936544	0.493936544	0.493936544
5	DS5	JAM	20.459999	0.51515154	1	0.850928683	0.51515154	0.677908147	0.51515154	0.51515154	1
6	DS6	RN	10.88	0.584946237	1	0.84516129	0.603763441	0.584946237	0.84516129	0.584946237	0.584946237
7	DS17	RN	12.33	0.436095506	1	0.551264045	1	0.865870787	0.436095506	0.436095506	0.865870787
8	DS27	PG2	14.066	0.600540541	1	0.661621622	0.760324324	0.600540541	0.436095506	0.760324324	0.760324324
9	DS40	PG2	57.400002	0.128222992	1	0.488327527	1	0.128222992	1	1	1
10	DSS1B	PG2	19.74	0.609929078	0.729898968	0.663627153	1	0.609929078	0.609929078	0.609929078	1
11	DSS1C	RN	5.7	0.342342342	0.593393393	0.565165165	1	0.342342342	0.342342342	0.342342342	0.342342342
12	DSS4	PG2	27.85	0.195332136	0.203590664	0.195332136	1	0.4502693	0.195332136	0.4502693	1
13	SINT-7-12	GEO	7.2475	0.344338954	0.344338954	0.41077789	1	0.701856313	0.344338954	0.344338954	0.41077789
14	SINT-13-7	RN	12.369375	0.363792034	0.363792034	0.440577687	1	0.736628622	0.363792034	0.363792034	0.736628622
15	SINT-13-7	PG2	15.090625	0.409277283	0.409277283	0.510209153	1	0.817933253	0.409277283	0.409277283	1
16	SINT-15-14	PG2	15.515938	0.396970844	0.396970844	0.491369777	1	0.795935637	0.396970844	0.396970844	1
17	SINT-15-14	JAM	6.125625	0.374276833	0.374276833	0.456628399	1	0.755370126	0.374276833	0.374276833	0.374276833
18	SINT-2-12	RN	18.869999	0.328828846	0.966216267	0.328828846	0.655537979	1	0.328828846	0.328828846	1
19	SINT-2-12	RN	14.65	0.250991615	0.434442467	0.250991615	1	0.645658852	0.250991615	0.250991615	0.645658852
20	SINT-3-19	PG2	14.098	0.513854826	1	0.513854826	0.82568176	0.932684212	0.513854826	0.513854826	0.82568176
21	SINT-3-19	RN	15.075	0.339011904	0.618537476	0.339011904	1	0.760365177	0.339011904	0.339011904	0.760365177
22	SINT-1-5	RN	8.83	0.380166612	1	0.636177943	0.380166612	0.555084115	0.380166612	0.380166612	0.555084115
23	SINT-1-5	RN	12.190001	0.477365737	1	0.790814348	0.477365737	0.643526548	0.477365737	0.477365737	0.643526548
24	SINT-22-23	JAM	16.666248	0.407785244	1	0.680117025	0.407785244	0.580214575	0.407785244	0.407785244	1
25	SINT-22-23	PG2	8.29375	0.456107789	1	0.756994514	0.456107789	0.62418368	0.456107789	0.456107789	0.456107789
26	SINT-13-17	PG2	17.323517	0.351409936	0.351409936	0.421622526	1	0.714495677	0.351409936	0.351409936	1
27	SINT-13-17	GEO	7.416953	0.366363057	0.366363057	0.444513626	1	0.741224366	0.366363057	0.366363057	0.444513626
28	SINT-2-21	RN	19.50375	0.328222116	1	0.328222116	0.521307488	0.981035403	0.328222116	0.328222116	0.981035403
29	SINT-2-21	RN	16.55125	0.399228443	0.887856413	0.399228443	1	0.992757258	0.399228443	0.399228443	0.992757258
30	SINT-6-11	GEO	14.1425	0.583739342	1	0.861297199	0.766443301	0.583739342	0.583739342	0.583739342	0.861297199
31	SINT-6-11	RN	6.995	0.457339	0.788492906	0.718372017	1	0.457339	0.457339	0.457339	0.457339




Figura F.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura F.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE G

EXPERIMENTO JAM X PG2

Tabela G.1: Experimento JAM x PG2

Num. Registro	Base	Variância	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE JAM	AE PG2	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	14.39	4.55	PG2	4.55	PG2	4.55	JAM	14.39
2	DS2	0.03944	0.45466	0.37182	0.1618	PG2	7.21	22.42	7.21	PG2	7.21	PG2	7.21	PG2	7.21
3	DS3	0.06978	0.69015	0.39584	0.16805	PG2	11.234	19.48	11.234	PG2	11.234	PG2	19.48	JAM	19.48
4	DS4	0.03793	0.70296	0.43633	0.05507	JAM	10.59	10.59	21.440001	PG2	21.440001	PG2	21.440001	PG2	21.440001
5	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	20.459999	10.54	JAM	20.459999	JAM	20.459999	JAM	20.459999
6	DS6	0.02785	0.19466	0.00867	0.14702	PG2	11.23	18.6	11.23	JAM	18.6	JAM	18.6	PG2	11.23
7	DS17	0.03392	0.451	0.02008	0.07325	JAM	6.21	6.21	14.24	PG2	14.24	PG2	14.24	PG2	14.24
8	DS27	0.03109	0.56245	0.71428	0.06449	PG2	14.066	18.5	14.066	PG2	14.066	PG2	14.066	JAM	18.5
9	DS40	0.02924	0.2158	0.35269	0.1444	JAM	14.5	14.5	57.400002	PG2	57.400002	PG2	57.400002	PG2	57.400002
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	JAM	14.41	14.41	19.74	JAM	14.41	JAM	14.41	PG2	19.74
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	JAM	9.88	9.88	16.65	PG2	16.65	JAM	16.65	JAM	9.88
12	DSSS4	0.03215	0.089	-0.03236	0.15702	JAM	5.67	5.67	27.85	JAM	5.67	JAM	5.67	PG2	27.85
13	SINT-11-12	0.027328	0.0986	0.129002	0.145957	JAM	8.8275	8.8275	19.450001	PG2	19.450001	JAM	8.8275	JAM	8.8275
14	SINT-11-12	0.030543	0.0922	0.021427	0.153333	JAM	6.7225	6.7225	25.049999	JAM	6.7225	JAM	6.7225	JAM	6.7225
15	SINT-10-14	0.027218	0.033002	0.094449	0.148516	JAM	12.488125	12.488125	21.067501	JAM	12.488125	JAM	12.488125	PG2	21.067501
16	SINT-10-14	0.029434	0.072468	0.045768	0.151727	JAM	8.644375	8.644375	23.7225	JAM	8.644375	JAM	8.644375	JAM	8.644375
17	SINT-16-15	0.02888	0.062601	0.057938	0.150924	JAM	9.605312	9.605312	23.05875	JAM	9.605312	JAM	9.605312	PG2	23.05875
18	SINT-16-15	0.027772	0.042869	0.082279	0.149318	JAM	11.527187	11.527187	21.731251	JAM	11.527187	JAM	11.527187	PG2	21.731251
19	SINT-10-18	0.026526	0.02067	0.109662	0.147512	JAM	13.689297	13.689297	20.237812	JAM	13.689297	JAM	13.689297	PG2	20.237812
20	SINT-10-18	0.027357	0.035469	0.091407	0.148716	JAM	12.24789	12.24789	21.233438	JAM	12.24789	JAM	12.24789	PG2	21.233438
21	SINT-7-20	0.032279	0.347117	0.037912	0.092117	JAM	7.719472	7.719472	15.988359	JAM	7.719472	JAM	7.719472	JAM	7.719472
22	SINT-7-20	0.028997	0.139352	0.073575	0.12985	JAM	10.738418	10.738418	19.485079	JAM	10.738418	JAM	10.738418	JAM	10.738418
23	SINT-5-8	0.020155	0.17809	0.28234	0.102343	PG2	11.421499	19.969999	11.421499	PG2	11.421499	PG2	11.421499	PG2	11.421499
24	SINT-5-8	0.027445	0.43433	0.5703	0.077108	PG2	13.1845	18.99	13.1845	PG2	13.1845	PG2	13.1845	JAM	18.99
25	SINT-5-24	0.019244	0.14606	0.246345	0.105497	PG2	11.201124	20.092499	11.201124	PG2	11.201124	PG2	11.201124	JAM	20.092499
26	SINT-5-24	0.024711	0.33824	0.462315	0.086571	PG2	12.523375	19.357498	12.523375	PG2	12.523375	PG2	12.523375	PG2	12.523375
27	SINT-8-26	0.029495	0.506397	0.651289	0.07001	PG2	13.680344	18.714375	13.680344	PG2	13.680344	PG2	13.680344	PG2	13.680344
28	SINT-8-26	0.026306	0.394292	0.525306	0.08105	PG2	12.909031	19.143124	12.909031	PG2	12.909031	PG2	12.909031	JAM	19.143124
29	SINT-23-28	0.021693	0.232141	0.343082	0.097019	PG2	11.793383	19.763279	11.793383	PG2	11.793383	PG2	11.793383	JAM	19.763279
30	SINT-23-28	0.024768	0.340242	0.464565	0.086373	PG2	12.537148	19.349842	12.537148	PG2	12.537148	PG2	12.537148	JAM	19.349842
31	SINT-26-30	0.024725	0.33874	0.462877	0.086521	PG2	12.526817	19.355583	12.526817	PG2	12.526817	PG2	12.526817	PG2	12.526817

Tabela G.2: Experimento JAM x PG2 - Modelo Aleatório e Dados Normalizados

Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE JAM	AE PG2	AE Árvore	AE Rede Neural	AE Modelo Aleat.
DS1	JAM	14.39	0.3161918	1	0.3161918	0.3161918	0.3161918	1
DS2	PG2	7.21	0.321587868	1	0.321587868	0.321587868	0.321587868	0.321587868
DS3	JAM	19.48	0.576694045	1	0.576694045	0.576694045	1	1
DS4	PG2	21.40001	0.493936544	0.493936544	1	1	1	1
DS5	JAM	20.459999	0.51515154	1	0.51515154	1	1	1
DS6	PG2	11.23	0.603763441	1	0.603763441	1	1	1
DS17	PG2	14.24	0.436095506	1	1	1	1	1
DS27	JAM	18.5	0.760324324	1	0.760324324	0.760324324	1	1
DS40	PG2	57.400002	0.252613232	1	1	1	1	1
DSSS1B	PG2	19.74	0.729989868	0.729989868	1	0.729989868	1	1
DSSS1C	JAM	9.88	0.593393393	0.593393393	1	1	1	0.593393393
DSSS4	PG2	27.85	0.203590664	0.203590664	1	0.203590664	0.203590664	1
SINT-11-12	JAM	8.8275	0.453856018	0.453856018	1	1	0.453856018	0.453856018
SINT-11-12	JAM	6.7225	0.268363284	0.268363284	1	0.268363284	0.268363284	0.268363284
SINT-10-14	PG2	21.067501	0.592767267	0.592767267	1	0.592767267	0.592767267	1
SINT-10-14	JAM	8.644375	0.364395616	0.364395616	1	0.364395616	0.364395616	0.364395616
SINT-16-15	PG2	23.05875	0.416558226	0.416558226	1	0.416558226	0.416558226	1
SINT-16-15	PG2	21.731251	0.530442863	0.530442863	1	0.530442863	0.530442863	1
SINT-10-18	PG2	20.237812	0.676421789	0.676421789	1	0.676421789	0.676421789	1
SINT-10-18	PG2	21.233438	0.576820862	0.576820862	1	0.576820862	0.576820862	1
SINT-7-20	JAM	7.719472	0.48281828	0.48281828	1	0.48281828	0.48281828	1
SINT-7-20	JAM	10.738418	0.5511098	0.5511098	1	0.5511098	0.5511098	0.48281828
SINT-5-8	PG2	11.421499	0.571932878	1	0.571932878	0.571932878	0.571932878	0.5511098
SINT-5-8	JAM	18.99	0.694286467	1	0.694286467	0.694286467	0.694286467	0.571932878
SINT-5-24	JAM	20.092499	0.557477893	1	0.557477893	0.557477893	0.557477893	1
SINT-5-24	PG2	12.523375	0.646952153	1	0.646952153	0.646952153	0.646952153	0.646952153
SINT-8-26	PG2	13.680344	0.73100726	1	0.73100726	0.73100726	0.73100726	0.646952153
SINT-8-26	JAM	19.143124	0.674342965	1	0.674342965	0.674342965	0.674342965	0.73100726
SINT-23-28	JAM	19.763279	0.596732101	1	0.596732101	0.596732101	0.596732101	1
SINT-23-28	JAM	19.349842	0.647919916	1	0.647919916	0.647919916	0.647919916	1
SINT-26-30	PG2	12.526817	0.64719399	1	0.64719399	0.64719399	0.64719399	0.64719399




Figura G.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura G.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE H

EXPERIMENTO PG1 X PG2

Tabela H.1: Experimento PG1 x PG2

Num. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE PG1	AE PG2	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	6.75	4.55	PG1	6.75	PG2	4.55	PG1	6.75
2	DS2	0.03944	0.45466	0.37182	0.1618	PG1	4.084	4.084	7.21	PG1	4.084	PG1	4.084	PG1	4.084
3	DS3	0.06978	0.69015	0.39584	0.16805	PG2	11.234	17.450001	11.234	PG1	17.450001	PG2	11.234	PG1	17.450001
4	DS4	0.03793	0.70296	0.43633	0.05507	PG1	15.864	15.864	21.440001	PG2	21.440001	PG2	21.440001	PG1	15.864
5	DS14C	0.06422	0.3703	0.09247	0.15079	PG2	13.906	356.410004	13.906	PG2	13.906	PG2	13.906	PG2	13.906
6	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	15.072	10.54	PG1	15.072	PG2	10.54	PG1	15.072
7	DS6	0.02785	0.19466	0.00867	0.14702	PG1	9.456	9.456	11.23	PG2	11.23	PG2	11.23	PG2	11.23
8	DS17	0.03392	0.451	0.02008	0.07325	PG1	9.68	9.68	14.24	PG2	14.24	PG2	14.24	PG1	9.68
9	DS27	0.03109	0.56245	0.71428	0.06449	PG2	14.066	17.66	14.066	PG1	17.66	PG1	17.66	PG1	17.66
10	DS40	0.02924	0.2158	0.35269	0.1444	PG1	38.818001	38.818001	57.400002	PG2	57.400002	PG2	57.400002	PG1	38.818001
11	DSS1A	0.05633	0.11014	0.1246	0.20658	PG1	8.616	8.616	12.32	PG2	12.32	PG2	12.32	PG2	12.32
12	DSS1B	0.02611	0.01327	0.11879	0.14691	PG1	9.798	9.798	19.74	PG2	19.74	PG1	9.798	PG2	19.74
13	DSS1C	0.02572	0.1018	0.18279	0.14227	PG1	10.462	10.462	16.65	PG1	10.462	PG1	10.462	PG1	10.462
14	DSS2	0.03939	-0.03565	-0.00136	0.17727	PG2	12.06	14.66	12.06	PG1	14.66	PG1	14.66	PG2	12.06
15	DSS3	0.02142	0.13134	0.11625	0.13551	PG2	11.08	14.772	11.08	PG2	11.08	PG2	11.08	PG1	14.772
16	DSS4	0.03215	0.089	-0.03236	0.15702	PG1	9.174	9.174	27.85	PG1	9.174	PG1	9.174	PG2	27.85
17	SINT-1-15	0.026948	0.301417	0.277065	0.134392	PG2	6.1825	8.7555	6.1825	PG2	6.1825	PG2	6.1825	PG1	8.7555
18	SINT-1-15	0.023263	0.188033	0.169855	0.135137	PG2	9.4475	12.7665	9.4475	PG1	12.7665	PG2	9.4475	PG2	9.4475
19	SINT-16-13	0.030543	0.0922	0.021427	0.153333	PG1	9.496	9.496	25.049999	PG1	9.496	PG1	9.496	PG1	9.496
20	SINT-16-13	0.027328	0.0986	0.129002	0.145957	PG1	10.139999	10.139999	19.450001	PG1	10.139999	PG1	10.139999	PG2	19.450001
21	SINT-19-20	0.029739	0.0938	0.048321	0.151489	PG1	9.657	9.657	23.65	PG1	9.657	PG1	9.657	PG2	23.65
22	SINT-19-20	0.028131	0.097	0.102109	0.147801	PG1	9.979	9.979	20.85	PG1	9.979	PG1	9.979	PG2	20.85
23	SINT-12-22	0.026615	0.034203	0.11462	0.147133	PG1	9.84325	9.84325	20.0175	PG2	20.0175	PG1	9.84325	PG1	9.84325
24	SINT-12-22	0.027626	0.076067	0.106279	0.147578	PG1	9.93375	9.93375	20.5725	PG1	9.93375	PG1	9.93375	PG1	9.93375
25	SINT-16-24	0.031019	0.085767	0.0023	0.15466	PG1	9.363937	9.363937	26.030624	PG1	9.363937	PG1	9.363937	PG2	26.030624
26	SINT-16-24	0.028757	0.079301	0.071619	0.149939	PG1	9.743813	9.743813	22.391876	PG1	9.743813	PG1	9.743813	PG1	9.743813
27	SINT-5-18	0.053981	0.324733	0.111816	0.146877	PG2	12.791375	270.499146	12.791375	PG2	12.791375	PG2	12.791375	PG1	270.499146
28	SINT-5-18	0.033502	0.233599	0.150509	0.139051	PG2	10.562125	98.677376	10.562125	PG2	10.562125	PG2	10.562125	PG1	98.677376
29	SINT-27-28	0.048861	0.30195	0.121489	0.14492	PG2	12.234062	227.543701	12.234062	PG1	227.543701	PG2	12.234062	PG1	227.543701
30	SINT-27-28	0.038622	0.256383	0.140836	0.141007	PG2	11.119438	141.632813	11.119438	PG2	11.119438	PG2	11.119438	PG2	11.119438
31	SINT-1-30	0.031248	0.332678	0.283211	0.135767	PG2	6.19236	40.470703	6.19236	PG2	6.19236	PG2	6.19236	PG1	40.470703

Tabela H.2: Experimento PG1 x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE PG1	AE PG2	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	PG1	6.75	0.674074074	1	0.674074074	1	0.674074074	1
2	DS2	PG1	4.084	0.566435506	0.566435506	1	0.566435506	0.566435506	0.566435506
3	DS3	PG1	17.450001	0.643782198	1	0.643782198	1	0.643782198	1
4	DS4	PG1	15.864	0.739925339	0.739925339	1	1	1	0.739925339
5	DS14C	PG2	13.906	0.039016862	1	0.039016862	0.039016862	0.039016862	0.039016862
6	DS5	PG1	15.072	0.699309979	1	0.699309979	1	0.699309979	1
7	DS6	PG2	11.23	0.842030276	0.842030276	1	1	1	1
8	DS17	PG1	9.68	0.679775281	0.679775281	1	1	1	0.679775281
9	DS27	PG1	17.66	0.796489241	1	0.796489241	1	1	1
10	DS40	PG1	38.818001	0.676271771	0.676271771	1	1	1	0.676271771
11	DS40	PG2	12.32	0.699350649	0.699350649	1	1	1	1
12	DSSS1A	PG2	19.74	0.496352584	0.496352584	1	1	0.496352584	1
13	DSSS1C	PG1	10.462	0.628348348	0.628348348	1	0.628348348	0.628348348	0.628348348
14	DSSS2	PG2	12.06	0.822646658	1	0.822646658	1	1	0.822646658
15	DSSS3	PG1	14.772	0.750067696	1	0.750067696	0.750067696	0.750067696	1
16	DSSS4	PG2	27.85	0.32940754	0.32940754	1	0.32940754	0.32940754	1
17	SINT-1-15	PG1	8.7555	0.706127577	1	0.706127577	0.706127577	0.706127577	1
18	SINT-1-15	PG2	9.4475	0.740022716	1	0.740022716	1	0.740022716	0.740022716
19	SINT-16-13	PG1	9.496	0.379081851	0.379081851	1	0.379081851	0.379081851	0.379081851
20	SINT-16-13	PG2	19.450001	0.521336683	0.521336683	1	0.521336683	0.521336683	1
21	SINT-19-20	PG2	23.65	0.40832981	0.40832981	1	0.40832981	0.40832981	1
22	SINT-19-20	PG2	20.85	0.478609113	0.478609113	1	0.478609113	0.478609113	1
23	SINT-12-22	PG1	9.84325	0.491732234	0.491732234	1	1	0.491732234	0.491732234
24	SINT-12-22	PG1	9.93375	0.482865476	0.482865476	1	0.482865476	0.482865476	0.482865476
25	SINT-16-24	PG2	26.030624	0.359727719	0.359727719	1	0.359727719	0.359727719	1
26	SINT-16-24	PG1	9.743813	0.435149471	0.435149471	1	0.435149471	0.435149471	0.435149471
27	SINT-5-18	PG1	270.499146	0.047288042	0.047288042	1	0.047288042	0.047288042	1
28	SINT-5-18	PG1	98.677376	0.107036946	0.107036946	1	0.107036946	0.107036946	1
29	SINT-27-28	PG1	227.543701	0.053765769	0.053765769	1	1	0.053765769	1
30	SINT-27-28	PG2	11.119438	0.078508912	0.078508912	1	0.078508912	0.078508912	0.078508912
31	SINT-1-30	PG1	40.470703	0.153008461	0.153008461	1	0.153008461	0.153008461	1




Figura H.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura H.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE I

EXPERIMENTO GEO X RN

Tabela I.1: Experimento GEO x RN

Num. Registro	Base	Variância	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE GEO	AE RN	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	RN	7.15	7.69	7.15	RN	7.15	RN	7.15	GEO	7.69
2	DS2	0.03944	0.45466	0.37182	0.1618	GEO	6.46	6.46	20.98	GEO	6.46	GEO	6.46	RN	20.98
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	9.8	16.35	GEO	9.8	GEO	9.8	RN	16.35
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	14.55	3.54	GEO	14.55	RN	3.54	RN	3.54
5	DS5	0.01651	0.04997	0.13836	0.11496	RN	13.87	17.41	13.87	RN	13.87	RN	13.87	GEO	17.41
6	DS6	0.02785	0.19466	0.00867	0.14702	RN	10.88	15.72	10.88	RN	10.88	GEO	15.72	RN	10.88
7	DS17	0.03392	0.451	0.02008	0.07325	GEO	7.85	7.85	12.33	GEO	7.85	GEO	7.85	RN	12.33
8	DS27	0.03109	0.56245	0.71428	0.06449	RN	11.11	12.24	11.11	GEO	12.24	RN	11.11	RN	11.11
9	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	28.03001	7.36	RN	7.36	RN	7.36	GEO	28.03001
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	RN	12.04	13.1	12.04	RN	12.04	RN	12.04	RN	12.04
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	RN	5.7	9.41	5.7	RN	5.7	RN	5.7	RN	5.7
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.44	12.54	GEO	5.44	GEO	5.44	RN	12.54
13	SINT-2-12	0.037617	0.363245	0.270775	0.160605	GEO	6.205	6.205	18.869999	GEO	6.205	GEO	6.205	GEO	6.205
14	SINT-2-12	0.033973	0.180415	0.068685	0.158215	GEO	5.695	5.695	14.65	GEO	5.695	GEO	5.695	RN	14.65
15	SINT-13-14	0.036706	0.317538	0.220253	0.160008	GEO	6.0775	6.0775	17.814999	GEO	6.0775	GEO	6.0775	RN	17.814999
16	SINT-13-14	0.034884	0.226123	0.119208	0.158812	GEO	5.8225	5.8225	15.704999	GEO	5.8225	GEO	5.8225	RN	15.704999
17	SINT-15-16	0.036251	0.294684	0.194991	0.159709	GEO	6.01375	6.01375	17.287498	GEO	6.01375	GEO	6.01375	GEO	6.01375
18	SINT-15-16	0.035339	0.248976	0.144469	0.159111	GEO	5.88625	5.88625	16.232498	GEO	5.88625	GEO	5.88625	RN	16.232498
19	SINT-7-18	0.034275	0.400494	0.051177	0.094715	GEO	7.359062	7.359062	13.305624	GEO	7.359062	GEO	7.359062	RN	13.305624
20	SINT-7-18	0.034985	0.290482	0.113372	0.137646	GEO	6.377187	6.377187	15.256874	GEO	6.377187	GEO	6.377187	GEO	6.377187
21	SINT-15-20	0.036276	0.313024	0.193532	0.154417	GEO	6.152422	6.152422	17.175468	GEO	6.152422	GEO	6.152422	GEO	6.152422
22	SINT-15-20	0.035415	0.303996	0.140092	0.143236	GEO	6.302265	6.302265	15.896405	GEO	6.302265	GEO	6.302265	GEO	6.302265
23	SINT-17-22	0.036042	0.297012	0.181266	0.155591	GEO	6.085879	6.085879	16.939724	GEO	6.085879	GEO	6.085879	RN	16.939724
24	SINT-17-22	0.035624	0.301668	0.153817	0.147354	GEO	6.230136	6.230136	16.244179	GEO	6.230136	GEO	6.230136	GEO	6.230136
25	SINT-6-11	0.027318	0.171445	0.0522	0.145833	RN	9.585	14.1425	9.585	RN	9.585	RN	9.585	GEO	14.1425
26	SINT-6-11	0.026253	0.125015	0.13926	0.143458	RN	6.995	10.9875	6.995	RN	6.995	RN	6.995	GEO	10.9875
27	SINT-26-25	0.026519	0.136623	0.117495	0.144051	RN	7.6425	11.776251	7.6425	RN	7.6425	RN	7.6425	GEO	11.776251
28	SINT-26-25	0.027051	0.159837	0.073965	0.145239	RN	8.9375	13.35375	8.9375	RN	8.9375	RN	8.9375	GEO	13.35375
29	SINT-1-28	0.028355	0.308542	0.266494	0.136825	RN	7.596875	9.105938	7.596875	RN	7.596875	RN	7.596875	GEO	9.105938
30	SINT-1-28	0.027486	0.209406	0.138141	0.142434	RN	8.490625	11.937813	8.490625	RN	8.490625	RN	8.490625	RN	8.490625
31	SINT-8-30	0.030189	0.474189	0.570245	0.083976	RN	10.455156	12.164454	10.455156	RN	10.455156	RN	10.455156	RN	10.455156

Tabela I.2: Experimento GEO x RN - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE GEO	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	GEO	7.69	0.929778934	1	0.929778934	0.929778934	0.929778934	1
2	DS2	RN	20.98	0.307912297	0.307912297	1	0.307912297	0.307912297	1
3	DS3	RN	16.35	0.599388379	0.599388379	1	0.599388379	0.599388379	1
4	DS4	RN	3.54	0.243298969	1	0.243298969	1	0.243298969	0.243298969
5	DS5	GEO	17.41	0.796668581	1	0.796668581	0.796668581	0.796668581	1
6	DS6	RN	10.88	0.692111959	1	0.692111959	0.692111959	0.692111959	1
7	DS17	RN	12.33	0.636658556	0.636658556	1	0.636658556	0.636658556	1
8	DS27	RN	11.11	0.907679739	1	0.907679739	0.907679739	0.907679739	1
9	DS40	GEO	28.030001	0.262575802	1	0.262575802	0.262575802	0.262575802	1
10	DSS1B	RN	12.04	0.919083969	1	0.919083969	0.919083969	0.919083969	0.919083969
11	DSS1C	RN	5.7	0.605738576	1	0.605738576	0.605738576	0.605738576	0.605738576
12	DSS4	RN	12.54	0.433811802	0.433811802	1	0.433811802	0.433811802	1
13	SINT-2-12	GEO	6.205	0.328828846	0.328828846	1	0.328828846	0.328828846	1
14	SINT-2-12	RN	14.65	0.388737201	0.388737201	1	0.388737201	0.388737201	1
15	SINT-13-14	RN	17.814999	0.341145122	0.341145122	1	0.341145122	0.341145122	1
16	SINT-13-14	RN	15.704999	0.370741826	0.370741826	1	0.370741826	0.370741826	1
17	SINT-15-16	GEO	6.01375	0.347866996	0.347866996	1	0.347866996	0.347866996	0.347866996
18	SINT-15-16	RN	16.232498	0.362621329	0.362621329	1	0.362621329	0.362621329	1
19	SINT-7-18	RN	13.305624	0.553079059	0.553079059	1	0.553079059	0.553079059	1
20	SINT-7-18	GEO	6.377187	0.417987787	0.417987787	1	0.417987787	0.417987787	0.417987787
21	SINT-15-20	GEO	6.152422	0.358209861	0.358209861	1	0.358209861	0.358209861	0.358209861
22	SINT-15-20	GEO	6.302265	0.396458507	0.396458507	1	0.396458507	0.396458507	0.396458507
23	SINT-17-22	RN	16.939724	0.359266715	0.359266715	1	0.359266715	0.359266715	1
24	SINT-17-22	GEO	6.230136	0.383530371	0.383530371	1	0.383530371	0.383530371	0.383530371
25	SINT-6-11	GEO	14.1425	0.677744387	1	0.677744387	0.677744387	0.677744387	1
26	SINT-6-11	GEO	10.9875	0.636632537	1	0.636632537	0.636632537	0.636632537	1
27	SINT-26-25	GEO	11.776251	0.648975637	1	0.648975637	0.648975637	0.648975637	1
28	SINT-26-25	GEO	13.35375	0.669287653	1	0.669287653	0.669287653	0.669287653	1
29	SINT-1-28	GEO	9.105938	0.83427704	1	0.83427704	0.83427704	0.83427704	1
30	SINT-1-28	RN	8.490625	0.711237896	0.711237896	1	0.711237896	0.711237896	0.711237896
31	SINT-8-30	RN	10.455156	0.859484199	1	0.859484199	0.859484199	0.859484199	0.859484199




Figura I.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura I.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE J

EXPERIMENTO GEO X PG2

Tabela J.1: Experimento GEO x PG2

Núm. Registro	Base	Variância	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE GEO	AE PG2	Classe Árvore	Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	7.69	4.55	GEO	7.69	PG2	4.55	PG2	4.55
2	DS2	0.03944	0.45466	0.37182	0.1618	GEO	6.46	6.46	7.21	GEO	6.46	GEO	6.46	GEO	6.46
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	9.8	11.234	GEO	9.8	GEO	9.8	GEO	9.8
4	DS4	0.03793	0.70296	0.43633	0.05507	GEO	14.55	14.55	21.440001	GEO	14.55	GEO	14.55	GEO	14.55
5	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	17.41	10.54	GEO	17.41	PG2	10.54	PG2	10.54
6	DS6	0.02785	0.19466	0.00867	0.14702	PG2	11.23	15.72	11.23	GEO	15.72	PG2	11.23	GEO	15.72
7	DS17	0.03392	0.451	0.02008	0.07325	GEO	7.85	7.85	14.24	GEO	7.85	PG2	7.85	PG2	14.24
8	DS27	0.03109	0.56245	0.71428	0.06449	GEO	12.24	12.24	14.066	GEO	12.24	GEO	12.24	PG2	14.066
9	DS40	0.02924	0.2158	0.35269	0.1444	GEO	28.030001	28.030001	57.400002	GEO	28.030001	PG2	28.030001	PG2	57.400002
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	GEO	13.1	13.1	19.74	GEO	13.1	GEO	13.1	GEO	13.1
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	GEO	9.41	9.41	16.65	GEO	9.41	GEO	9.41	GEO	9.41
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.44	27.85	GEO	5.44	GEO	5.44	GEO	5.44
13	SINT-5-6	0.019345	0.086142	0.105937	0.122975	PG2	10.7125	16.987499	10.7125	GEO	16.987499	PG2	10.7125	GEO	16.987499
14	SINT-5-6	0.025015	0.158487	0.041093	0.139005	PG2	11.0575	16.1425	11.0575	PG2	11.0575	PG2	11.0575	GEO	16.1425
15	SINT-1-14	0.027846	0.308204	0.258276	0.135266	PG2	6.176875	9.803125	6.176875	PG2	6.176875	PG2	6.176875	GEO	9.803125
16	SINT-1-14	0.025959	0.208393	0.113487	0.137759	PG2	9.430625	14.029375	9.430625	PG2	9.430625	PG2	9.430625	PG2	9.430625
17	SINT-15-16	0.027374	0.283252	0.222078	0.135889	PG2	6.990313	10.859688	6.990313	PG2	6.990313	PG2	6.990313	PG2	6.990313
18	SINT-15-16	0.026431	0.233346	0.149684	0.137136	PG2	8.617188	12.972813	8.617188	PG2	8.617188	PG2	8.617188	PG2	8.617188
19	SINT-11-12	0.027328	0.0986	0.129002	0.145957	GEO	8.4175	8.4175	19.450001	GEO	8.4175	GEO	8.4175	GEO	8.4175
20	SINT-11-12	0.030543	0.0922	0.021427	0.153333	GEO	6.4325	6.4325	25.049999	GEO	6.4325	GEO	6.4325	PG2	25.049999
21	SINT-4-20	0.036083	0.55027	0.332604	0.079636	GEO	12.520625	12.520625	22.342499	GEO	12.520625	GEO	12.520625	GEO	12.520625
22	SINT-4-20	0.032389	0.24489	0.125153	0.128767	GEO	8.461875	8.461875	24.147499	GEO	8.461875	GEO	8.461875	PG2	24.147499
23	SINT-10-22	0.02768	0.071175	0.120381	0.142374	GEO	11.940469	11.940469	20.841873	GEO	11.940469	GEO	11.940469	GEO	11.940469
24	SINT-10-22	0.03082	0.186985	0.123562	0.133303	GEO	9.621407	9.621407	23.045624	GEO	9.621407	GEO	9.621407	GEO	9.621407
25	SINT-12-24	0.031817	0.113496	0.006621	0.151091	GEO	6.485352	6.485352	26.648907	GEO	6.485352	GEO	6.485352	PG2	26.648907
26	SINT-12-24	0.031152	0.162489	0.084582	0.139232	GEO	8.576056	8.576056	24.246717	GEO	8.576056	GEO	8.576056	GEO	8.576056
27	SINT-16-18	0.026077	0.214631	0.122536	0.137603	PG2	9.227266	13.765234	9.227266	PG2	9.227266	PG2	9.227266	PG2	9.227266
28	SINT-16-18	0.026313	0.227108	0.140635	0.137291	PG2	8.820547	13.236954	8.820547	PG2	8.820547	PG2	8.820547	PG2	8.820547
29	SINT-17-28	0.027109	0.269216	0.201718	0.13624	PG2	7.447871	11.454004	7.447871	PG2	7.447871	PG2	7.447871	PG2	7.447871
30	SINT-17-28	0.026578	0.241144	0.160996	0.136941	PG2	8.362988	12.642637	8.362988	PG2	8.362988	PG2	8.362988	PG2	8.362988
31	SINT-17-30	0.027175	0.272725	0.206808	0.136152	PG2	7.333482	11.305426	7.333482	PG2	7.333482	PG2	7.333482	GEO	11.305426

Tabela J.2: Experimento GEO x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE GEO	AE PG2	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	PG2	4.55	0.591677503	1	0.591677503	1	0.591677503	0.591677503
2	DS2	GEO	6.46	0.895977809	0.895977809	1	0.895977809	0.895977809	0.895977809
3	DS3	GEO	9.8	0.872351789	0.872351789	1	0.872351789	0.872351789	0.872351789
4	DS4	GEO	14.55	0.678638028	0.678638028	1	0.678638028	0.678638028	0.678638028
5	DS5	PG2	10.54	0.605399196	1	0.605399196	1	0.605399196	0.605399196
6	DS6	GEO	15.72	0.71437659	1	0.71437659	1	0.71437659	1
7	DS17	PG2	14.24	0.551264045	1	0.551264045	1	0.551264045	1
8	DS27	PG2	14.066	0.870183421	0.870183421	1	0.870183421	0.870183421	1
9	DS40	PG2	57.400002	0.488327527	0.488327527	1	0.488327527	0.488327527	1
10	DSS1B	GEO	13.1	0.663627153	0.663627153	1	0.663627153	0.663627153	0.663627153
11	DSS1C	GEO	9.41	0.565165165	0.565165165	1	0.565165165	0.565165165	0.565165165
12	DSSS4	GEO	5.44	0.195332136	0.195332136	1	0.195332136	0.195332136	0.195332136
13	SINT-5-6	GEO	16.987499	0.63061078	1	0.63061078	1	0.63061078	1
14	SINT-5-6	GEO	16.1425	0.684993031	0.684993031	1	0.684993031	0.684993031	1
15	SINT-1-14	GEO	9.803125	0.630092445	1	0.630092445	0.630092445	0.630092445	1
16	SINT-1-14	PG2	9.430625	0.67220564	0.67220564	1	0.67220564	0.67220564	0.67220564
17	SINT-15-16	PG2	6.990313	0.643693723	0.643693723	1	0.643693723	0.643693723	0.643693723
18	SINT-15-16	PG2	8.617188	0.664249766	0.664249766	1	0.664249766	0.664249766	0.664249766
19	SINT-11-12	GEO	8.4175	0.432776327	0.432776327	1	0.432776327	0.432776327	0.432776327
20	SINT-11-12	PG2	25.049999	0.256786437	0.256786437	1	0.256786437	0.256786437	1
21	SINT-11-12	GEO	12.520625	0.560395012	0.560395012	1	0.560395012	0.560395012	0.560395012
22	SINT-4-20	PG2	24.147499	0.350424489	0.350424489	1	0.350424489	0.350424489	1
23	SINT-10-22	GEO	11.940469	0.572907675	0.572907675	1	0.572907675	0.572907675	0.572907675
24	SINT-10-22	GEO	9.621407	0.417493881	0.417493881	1	0.417493881	0.417493881	0.417493881
25	SINT-12-24	PG2	26.648907	0.243362777	0.243362777	1	0.243362777	0.243362777	1
26	SINT-12-24	GEO	8.576056	0.353699678	0.353699678	1	0.353699678	0.353699678	0.353699678
27	SINT-16-18	PG2	9.227266	0.670331213	0.670331213	1	0.670331213	0.670331213	0.670331213
28	SINT-16-18	PG2	8.820547	0.666357759	0.666357759	1	0.666357759	0.666357759	0.666357759
29	SINT-17-28	PG2	7.447871	0.650241697	0.650241697	1	0.650241697	0.650241697	0.650241697
30	SINT-17-28	PG2	8.362988	0.661490795	0.661490795	1	0.661490795	0.661490795	0.661490795
31	SINT-17-30	GEO	11.305426	0.648669232	0.648669232	1	0.648669232	0.648669232	1




Figura J.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura J.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE K

EXPERIMENTO GEO X RN X PG2

Tabela K.1: Experimento GEO x RN x PG2

Núm. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE	AE	AE	Classe Árvore	AE Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	7.69	7.15	4.55	PG2	4.55	PG2	4.55	GEO	7.69
2	DS2	0.03944	0.45466	0.1618	0.1618	GEO	6.46	6.46	20.98	6.46	GEO	6.46	GEO	6.46	RN	20.98
3	DS3	0.06978	0.69015	0.39584	0.16805	GEO	9.8	9.8	16.35	9.8	GEO	9.8	GEO	9.8	RN	16.35
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	14.55	3.54	21.440001	PG2	14.55	GEO	14.55	PG2	21.440001
5	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	17.41	13.87	10.54	PG2	10.54	PG2	10.54	PG2	10.54
6	DS6	0.02785	0.19466	0.00867	0.14702	RN	10.88	15.72	10.88	11.23	PG2	10.88	GEO	15.72	GEO	15.72
7	DS17	0.03392	0.451	0.02008	0.07325	GEO	7.85	7.85	12.33	7.85	GEO	7.85	GEO	7.85	RN	12.33
8	DS27	0.03109	0.56245	0.71428	0.06449	RN	11.11	12.24	11.11	14.066	GEO	12.24	PG2	14.066	PG2	14.066
9	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	28.030001	7.36	57.400002	RN	7.36	PG2	57.400002	RN	7.36
10	DSSS1B	0.02611	0.01327	0.11879	0.14691	RN	12.04	13.1	12.04	19.74	RN	12.04	RN	12.04	RN	12.04
11	DSSS1C	0.02572	0.1018	0.18279	0.14227	RN	5.7	9.41	5.7	16.65	RN	5.7	RN	16.65	PG2	16.65
12	DSSS4	0.03215	0.089	-0.03236	0.15702	GEO	5.44	5.44	12.54	27.85	GEO	5.44	GEO	5.44	RN	12.54
13	SINT-12-7	0.032593	0.1795	-0.01925	0.136077	GEO	6.0425	6.0425	12.487499	24.4475	GEO	6.0425	GEO	6.0425	PG2	24.4475
14	SINT-12-7	0.033478	0.3605	0.00697	0.094193	GEO	7.2475	7.2475	12.3825	17.6425	GEO	7.2475	GEO	7.2475	RN	12.3825
15	SINT-1-5	0.02572	0.281075	0.282593	0.129255	PG2	6.0475	10.12	8.83	6.0475	PG2	6.0475	PG2	6.0475	RN	8.83
16	SINT-1-5	0.01958	0.127005	0.186437	0.119725	PG2	9.0425	14.98	12.1900001	9.0425	PG2	9.0425	PG2	9.0425	RN	12.1900001
17	SINT-1-16	0.026487	0.300334	0.294612	0.130446	PG2	5.673125	9.5125	8.41	5.673125	PG2	5.673125	PG2	5.673125	GEO	9.5125
18	SINT-1-16	0.021883	0.184781	0.222496	0.123299	PG2	7.919374	13.157499	10.93	7.919374	PG2	7.919374	PG2	7.919374	GEO	13.157499
19	SINT-7-14	0.033809	0.428375	0.016803	0.078486	GEO	7.699375	7.699375	12.343124	15.090625	GEO	7.699375	GEO	7.699375	RN	12.343124
20	SINT-7-14	0.033588	0.383125	0.010248	0.088957	GEO	7.398125	7.398125	12.369375	16.791874	GEO	7.398125	GEO	7.398125	RN	12.369375
21	SINT-12-20	0.03251	0.162531	-0.021708	0.140004	GEO	5.929531	5.929531	12.497343	25.085468	GEO	5.929531	GEO	5.929531	PG2	25.085468
22	SINT-12-20	0.033229	0.309594	-0.000404	0.105973	GEO	6.908594	6.908594	12.412031	19.556406	GEO	6.908594	GEO	6.908594	GEO	6.908594
23	SINT-2-22	0.037887	0.418393	0.278764	0.147833	GEO	6.572148	6.572148	18.838007	10.296602	GEO	6.572148	GEO	6.572148	RN	18.838007
24	SINT-2-22	0.034781	0.34586	0.092652	0.119929	GEO	6.796445	6.796445	14.554023	16.469805	GEO	6.796445	GEO	6.796445	RN	6.796445
25	SINT-6-11	0.027318	0.171445	0.0522	0.145833	RN	9.585	14.1425	9.585	12.584999	RN	9.585	RN	9.585	GEO	14.1425
26	SINT-6-11	0.026253	0.125015	0.13926	0.143458	RN	6.995	10.9875	6.995	15.295	RN	6.995	RN	6.995	PG2	15.295
27	SINT-10-26	0.026146	0.041206	0.123907	0.146047	RN	10.778749	12.571876	10.778749	18.62875	RN	10.778749	RN	10.778749	PG2	18.62875
28	SINT-10-26	0.026217	0.097079	0.134142	0.144321	RN	8.25625	11.515625	8.25625	16.40625	RN	8.25625	RN	8.25625	GEO	11.515625
29	SINT-26-28	0.026244	0.118031	0.137981	0.143673	RN	7.310312	11.119532	7.310312	15.572813	RN	7.310312	RN	7.310312	PG2	15.572813
30	SINT-26-28	0.026226	0.104063	0.135422	0.144105	RN	7.940938	11.383594	7.940938	16.128437	RN	7.940938	RN	7.940938	RN	7.940938
31	SINT-18-17	0.023034	0.213669	0.240525	0.125086	PG2	7.357812	12.246249	10.3	7.357812	PG2	7.357812	PG2	7.357812	RN	10.3

Tabela K.2: Experimento GEO x RN x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE GEO	AE PG2	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	GEO	7.69	0.591677503	1	0.591677503	0.929778934	0.591677503	0.591677503	1
2	DS2	RN	20.98	0.307912297	0.307912297	0.343660629	1	0.307912297	0.307912297	1
3	DS3	RN	16.35	0.599388379	0.599388379	0.687094801	1	0.599388379	0.599388379	1
4	DS4	PG2	21.440001	0.165111933	0.678638028	1	0.165111933	0.678638028	0.678638028	1
5	DS5	PG2	10.54	0.605399196	1	0.605399196	0.796668581	0.605399196	0.605399196	1
6	DS6	GEO	15.72	0.692111959	0.551264045	1	0.692111959	0.692111959	1	1
7	DS17	RN	12.33	0.551264045	0.870183421	1	0.865870787	0.551264045	0.551264045	1
8	DS27	PG2	14.066	0.78984786	0.488327527	1	0.78984786	0.870183421	1	1
9	DS40	RN	7.36	0.128222992	0.663627153	1	0.128222992	0.128222992	1	1
10	DSS1B	RN	12.04	0.609929078	0.663627153	1	0.609929078	0.609929078	0.609929078	1
11	DSS1C	PG2	16.65	0.342342342	0.342342342	1	0.342342342	0.342342342	0.342342342	1
12	DSS4	RN	12.54	0.195332136	0.195332136	1	0.4502693	0.195332136	0.195332136	0.4502693
13	SINT-12-7	PG2	24.4475	0.247162287	0.247162287	1	0.510788383	0.247162287	0.247162287	1
14	SINT-12-7	RN	12.3825	0.410797789	0.410797789	1	0.701856313	0.410797789	0.410797789	0.701856313
15	SINT-1-5	RN	8.83	0.597579051	1	0.597579051	0.872529644	0.597579051	0.597579051	0.872529644
16	SINT-1-5	RN	12.190001	0.603638184	1	0.603638184	0.813751736	0.603638184	0.603638184	0.813751736
17	SINT-1-16	GEO	9.5125	0.596386334	1	0.596386334	0.596386334	0.596386334	1	1
18	SINT-1-16	GEO	13.157499	0.601890526	1	0.601890526	0.601890526	0.601890526	0.601890526	1
19	SINT-7-14	RN	12.343124	0.510209153	0.510209153	1	0.817933253	0.510209153	0.510209153	0.817933253
20	SINT-7-14	RN	12.369375	0.440577687	0.440577687	1	0.736628622	0.440577687	0.440577687	0.736628622
21	SINT-12-20	PG2	25.085468	0.236373146	0.236373146	1	0.498190546	0.236373146	0.236373146	1
22	SINT-12-20	GEO	6.908594	0.353265012	0.353265012	1	0.634678529	0.353265012	0.353265012	0.353265012
23	SINT-2-22	RN	18.838007	0.348877034	0.348877034	1	1	0.348877034	0.348877034	1
24	SINT-2-22	GEO	6.796445	0.412660927	0.412660927	1	0.883679133	0.412660927	0.412660927	0.412660927
25	SINT-6-11	GEO	14.1425	0.677744387	0.677744387	1	0.677744387	0.677744387	0.677744387	1
26	SINT-6-11	PG2	15.295	0.457339	0.457339	1	0.457339	0.457339	0.457339	1
27	SINT-10-26	PG2	18.62875	0.57860828	0.57860828	1	0.57860828	0.57860828	0.57860828	1
28	SINT-10-26	GEO	11.515625	0.674864175	0.674864175	1	0.503238095	0.503238095	0.503238095	0.701904762
29	SINT-26-28	PG2	15.572813	0.469427842	0.701904762	1	0.469427842	0.469427842	0.469427842	1
30	SINT-26-28	RN	7.940938	0.492356327	0.705808877	1	0.492356327	0.492356327	0.492356327	0.492356327
31	SINT-18-17	RN	10.3	0.600821688	1	0.600821688	0.841073867	0.600821688	0.600821688	0.841073867




Figura K.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura K.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

APÊNDICE L

EXPERIMENTO RN X PG2

Tabela L.1: Experimento RN x PG2

Num. Registro	Base	Variação	Inclinação	Auto-Correlação	Ruído Médio	Classe	AE Ótimo	AE PG2	AE RN	Classe Árvore	AE Árvore	Classe Rede Neural	AE Rede Neural	Modelo Aleat.	AE Modelo Aleat.
1	DS1	0.02879	0.35811	0.33067	0.13402	PG2	4.55	4.55	7.15	PG2	4.55	PG2	4.55	RN	7.15
2	DS2	0.03944	0.45466	0.37182	0.1618	PG2	7.21	7.21	20.98	PG2	7.21	PG2	7.21	RN	20.98
3	DS3	0.06978	0.69015	0.39584	0.16805	PG2	11.234	11.234	16.35	RN	16.35	PG2	11.234	PG2	11.234
4	DS4	0.03793	0.70296	0.43633	0.05507	RN	3.54	21.440001	3.54	PG2	21.440001	PG2	21.440001	RN	3.54
5	DS14C	0.06422	0.3703	0.09247	0.15079	PG2	6.32	13.906	6.32	RN	6.32	RN	6.32	PG2	13.906
6	DS5	0.01651	0.04997	0.13836	0.11496	PG2	10.54	10.54	13.87	RN	13.87	RN	13.87	PG2	10.54
7	DS6	0.02785	0.19466	0.00867	0.14702	RN	10.88	11.23	10.88	RN	10.88	RN	10.88	RN	10.88
8	DS17	0.03392	0.451	0.02008	0.07325	RN	12.33	14.24	12.33	RN	12.33	PG2	14.24	PG2	14.24
9	DS27	0.03109	0.56245	0.71428	0.06449	RN	11.11	14.066	11.11	PG2	14.066	PG2	14.066	RN	11.11
10	DS40	0.02924	0.2158	0.35269	0.1444	RN	7.36	57.400002	7.36	PG2	57.400002	PG2	57.400002	RN	7.36
11	DS51A	0.05633	0.11014	0.1246	0.20658	RN	5.17	12.32	5.17	RN	5.17	PG2	5.17	PG2	12.32
12	DS51B	0.02611	0.01327	0.11879	0.14691	RN	12.04	19.74	12.04	RN	12.04	RN	12.04	RN	12.04
13	DS51C	0.02572	0.1018	0.18279	0.14227	RN	5.7	16.65	5.7	PG2	16.65	RN	5.7	PG2	16.65
14	DS52	0.03939	-0.03565	-0.00136	0.17727	RN	7.52	12.06	7.52	RN	7.52	RN	7.52	RN	7.52
15	DS53	0.02142	0.13134	0.11625	0.13551	RN	3.62	11.08	3.62	RN	3.62	RN	3.62	PG2	11.08
16	DS54	0.03215	0.089	-0.03236	0.15702	RN	12.54	27.85	12.54	RN	12.54	RN	12.54	PG2	27.85
17	SINT-2-6	0.033707	0.353487	0.313455	0.15009	PG2	8.0425	8.0425	19.202499	PG2	8.0425	PG2	8.0425	RN	19.202499
18	SINT-2-6	0.022243	0.151142	0.196725	0.12667	PG2	9.7075	9.7075	15.647499	PG2	9.7075	PG2	9.7075	PG2	9.7075
19	SINT-1-18	0.027153	0.306368	0.297184	0.132183	PG2	5.839375	5.839375	9.274375	PG2	5.839375	PG2	5.839375	RN	9.274375
20	SINT-1-18	0.023879	0.202884	0.230211	0.128507	PG2	8.418125	8.418125	13.523125	PG2	8.418125	PG2	8.418125	PG2	8.418125
21	SINT-18-20	0.022652	0.164078	0.205097	0.127129	PG2	9.385157	9.385157	15.116405	PG2	9.385157	PG2	9.385157	PG2	9.385157
22	SINT-18-20	0.02347	0.189949	0.22184	0.128048	PG2	8.740469	8.740469	14.054218	PG2	8.740469	PG2	8.740469	PG2	8.740469
23	SINT-2-22	0.035448	0.388482	0.334325	0.153362	PG2	7.592617	7.592617	19.248554	PG2	7.592617	PG2	7.592617	PG2	7.592617
24	SINT-2-22	0.027463	0.256127	0.259335	0.136486	PG2	8.357852	8.357852	15.785664	PG2	8.357852	PG2	8.357852	PG2	8.357852
25	SINT-7-16	0.028925	0.168245	-0.001587	0.14952	RN	11.295	15.385	11.295	RN	11.295	RN	11.295	PG2	15.385
26	SINT-7-16	0.031075	0.115415	-0.022102	0.15452	RN	12.125	23.695	12.125	RN	12.125	RN	12.125	RN	12.125
27	SINT-13-26	0.027059	0.105204	0.131567	0.145353	RN	7.30625	18.411251	7.30625	PG2	18.411251	RN	7.30625	RN	7.30625
28	SINT-13-26	0.029736	0.112011	0.029121	0.151458	RN	10.51875	21.933375	10.51875	RN	10.51875	RN	10.51875	RN	10.51875
29	SINT-21-24	0.023854	0.18709	0.218656	0.129469	PG2	9.12833	9.12833	15.28372	PG2	9.12833	PG2	9.12833	RN	15.28372
30	SINT-21-24	0.02626	0.233114	0.245775	0.134147	PG2	8.614677	8.614677	15.618349	PG2	8.614677	PG2	8.614677	RN	15.618349
31	SINT-3-30	0.0589	0.575891	0.358324	0.159574	PG2	10.57917	10.57917	16.167088	PG2	10.57917	PG2	10.57917	RN	16.167088

Tabela L.2: Experimento RN x PG2 - Modelo Aleatório e Dados Normalizados

Num.Registro	Base	Modelo Aleat.	AE Modelo Aleat.	AE Ótimo	AE PG2	AE RN	AE Árvore	AE Rede Neural	AE Modelo Aleat.
1	DS1	RN	7.15	0.636363636	0.636363636	1	0.636363636	0.636363636	1
2	DS2	RN	20.98	0.343660629	0.343660629	1	0.343660629	0.343660629	1
3	DS3	PG2	11.234	0.687094801	0.687094801	1	1	0.687094801	0.687094801
4	DS4	RN	3.54	0.165111933	0.165111933	1	1	0.165111933	0.165111933
5	DS14C	PG2	13.906	0.454480081	1	0.454480081	1	0.454480081	1
6	DS5	PG2	10.54	0.759913482	0.759913482	1	1	0.759913482	0.759913482
7	DS6	RN	10.88	0.968833482	1	0.968833482	1	0.968833482	0.968833482
8	DS17	PG2	14.24	0.865870787	1	0.865870787	1	1	1
9	DS27	RN	11.11	0.78984786	1	0.78984786	1	1	0.78984786
10	DS40	RN	7.36	0.128222992	1	0.128222992	1	1	0.128222992
11	DS40	RN	7.36	0.128222992	1	0.128222992	1	1	0.128222992
12	DSSS1A	PG2	12.32	0.419642857	0.419642857	1	0.419642857	0.419642857	1
13	DSSS1B	RN	12.04	0.609929078	0.609929078	1	0.609929078	0.609929078	0.609929078
14	DSSS1C	PG2	16.65	0.342342342	0.342342342	1	1	0.342342342	1
15	DSSS2	RN	7.52	0.623548922	0.623548922	1	0.623548922	0.623548922	0.623548922
16	DSSS3	PG2	11.08	0.326714801	0.326714801	1	0.326714801	0.326714801	1
17	DSSS4	PG2	27.85	0.4502693	0.4502693	1	0.4502693	0.4502693	1
18	SINT-2-6	RN	19.202499	0.418825696	0.418825696	1	0.418825696	0.418825696	1
19	SINT-1-18	PG2	9.7075	0.620386683	0.620386683	1	0.620386683	0.620386683	0.620386683
20	SINT-1-18	PG2	9.274375	0.629624638	0.629624638	1	0.629624638	0.629624638	1
21	SINT-1-18	PG2	8.418125	0.622498498	0.622498498	1	0.622498498	0.622498498	0.622498498
22	SINT-18-20	PG2	9.385157	0.62085906	0.62085906	1	0.62085906	0.62085906	0.62085906
23	SINT-2-22	PG2	8.740469	0.621910732	0.621910732	1	0.621910732	0.621910732	0.621910732
24	SINT-2-22	PG2	7.592617	0.394451292	0.394451292	1	0.394451292	0.394451292	0.394451292
25	SINT-7-16	PG2	8.357852	0.529458374	0.529458374	1	0.529458374	0.529458374	0.529458374
26	SINT-7-16	PG2	15.385	0.734156646	0.734156646	1	0.734156646	0.734156646	1
27	SINT-7-16	RN	12.125	0.511711332	0.511711332	1	0.511711332	0.511711332	0.511711332
28	SINT-13-26	RN	7.30625	0.396836152	0.396836152	1	0.396836152	0.396836152	0.396836152
29	SINT-13-26	RN	10.51875	0.479569157	0.479569157	1	0.479569157	0.479569157	0.479569157
30	SINT-21-24	RN	15.28372	0.59725839	0.59725839	1	0.59725839	0.59725839	1
31	SINT-21-24	RN	15.618349	0.551574113	0.551574113	1	0.551574113	0.551574113	1
32	SINT-3-30	RN	16.167088	0.654364596	0.654364596	1	0.654364596	0.654364596	1




Figura L.1: % de Melhora na Utilização de Meta-Aprendizado com Árvore de Decisão




Figura L.2: % de Melhora na Utilização de Meta-Aprendizado com Rede Neural

RAFAEL CAIUTA

**UTILIZANDO META-APRENDIZADO PARA SELEÇÃO DE
MODELOS DE CONFIABILIDADE DE SOFTWARE**

Dissertação apresentada como requisito parcial à obtenção do grau de Mestre. Programa de Pós-Graduação em Informática, Setor de Ciências Exatas, Universidade Federal do Paraná.

Orientadora: Profa. Dra. Silvia Regina Vergilio.

Co-Orientadora: Profa. Dra. Aurora Trinidad Ramirez Pozo

CURITIBA

2007